

Predykcyjne utrzymanie ruchu w energetyce

Od fizyki degradacji po autonomiczne systemy decyzyjne — zintegrowany raport 2026

Spis treści

[A. Fizyka degradacji i mechanizmy awarii](#)

- [A1. Transformatory](#) · [A2. Turbiny wiatrowe](#) · [A3. Panele PV](#) · [A4. Linie przesyłowe](#) · [A5. Infrastruktura stacyjna](#)

[B. Architektura danych i algorytmy ML/DL](#)

- [B1. Pipeline danych](#) · [B2. Algorytmy](#) · [B3. Syntetyczne dane](#)

[C. Platformy vendorów](#) — C1–C8 + [Tabela porównawcza](#) + [Wady vendorów](#) + [Matryca decyzyjna](#)

[D. Od Predictive do Prescriptive i Autonomous](#)

- [D1. Prescriptive workflow](#) · [D2. Autonomous](#) · [D3. Digital Twin + RL](#)

[E. Ekonomia](#) — [Koszty awarii](#) · [TCO](#)

[F. Bariery](#) — [Dane](#) · [Zaufanie](#) · [EU AI Act](#) · [Polska](#)

[Wnioski](#)

Wizualizacje: [Rys. 1 — Krzywa degradacji DP](#) · [Rys. 2 — Pipeline danych PdM](#) · [Rys. 3 — Dobór algorytmu ML](#) · [Rys. 4 — Mapa vendorów](#)

\$3–5 mln. Tyle kosztuje dziś nowy transformator mocy powyżej 100 MVA. Czas dostawy? Od 80 do 210 tygodni — czyli od półtora do czterech lat. A 70% transformatorów w USA i 40% infrastruktury sieciowej w Europie przekroczyło już projektową żywotność. Zbliżamy się do „klifu awaryjnego” — momentu, gdy starzejące się aktywa zaczną padać szybciej niż jesteśmy w stanie je wymieniać.

Predykcyjne utrzymanie ruchu (PdM) to jedyna sensowna odpowiedź na ten problem. Nie dlatego, że jest modne. Dlatego, że matematyka jest brutalna: naprawienie czegoś planowo kosztuje 10–30 razy mniej niż naprawienie tego samego w panice.

Ten raport schodzi głęboko. Nie jest dla zarządu — jest dla inżyniera, który chce wiedzieć jakie gazy w oleju transformatorowym wskazują na łuk elektryczny, dlaczego kurtoza wibracji łożyska skacze z 3 do 8 na trzy miesiące przed awarią, i który vendor naprawdę dostarcza to, co obiecuje w broszurze. Pokrywamy pełny łańcuch: od fizyki degradacji aktywów, przez sensory i akwizycję danych, algorytmy ML/DL wdrożone w produkcji (nie w paperach), platformy vendorów z konkretnymi cenami i referencjami, aż po prescriptive maintenance i autonomiczne drony inspekcyjne.

A. Fizyka degradacji i mechanizmy awarii

A1. Transformatory — najdroższe i najtrudniej wymienialne aktywa w sieci

Transformator mocy to najdroższy pojedynczy element w sieci elektroenergetycznej. Gdy pada — nie idziesz do sklepu po nowy. Idziesz do kolejki, w której stoją wszyscy operatorzy sieci na kontynencie, i czekasz. 80 do 210 tygodni. A w tym czasie Twoi klienci siedzą bez prądu albo obciążasz sąsiednie transformatory ponad normę, przyspieszając ich degradację. Efekt domina.

Jak umiera transformator? Degradacja izolacji papierowej przebiega zgodnie z kinetyką Arrheniusa — to ta sama chemia, która sprawia, że papier żółknie na słońcu, tyle że w oleju transformatorowym przy 80–130°C. Szybkość hydrolizy celulozy opisuje równanie Ekenstama:

$$1/DP(t) - 1/DP_0 = A \times \exp(-E_a/RT) \times t$$

Nowa izolacja ma DP (stopień polimeryzacji) = 1000–1300. Próg końca życia to $DP \leq 200$ (IEEE) lub <150 (CIGRE). I tu jest pułapka, którą wielu ludzi przegapia: **awaria mechaniczna poprzedza awarię elektryczną**. Papier o niskim DP wytrzymuje napięcie — ale pęka przy pierwszym zwarcu. Transformator wygląda na zdrowy, aż nagle nie jest.

Wilgotność dramatycznie przyspiesza starzenie: wzrost z 1% do 3% zawartości wody w temperaturze 90–130°C skraca żywotność wielokrotnie. Bezpośredni pomiar DP wymaga destrukcyjnego próbkowania (musisz otworzyć transformator i wyciąć kawałek papieru), więc w praktyce stosuje się estymację pośrednią — przez analizę furfuralu (2-FAL), stosunku CO/CO_2 i metanolu w oleju. Metoda Chendonga jest uważana za najsolidniejszą ($R^2 = 0,677$, $CC = 0,878$), choć — bądźmy szczerzy — te korelacje są dalekie od ideału. To jest otwarte napięcie w tej dziedzinie.

Rys. 1 — Krzywa degradacji DP. Reguła 6°C: każde +6°C ≈ połowa żywotności. Wilgotność 3% vs 1% przy 95°C skraca życie z ~15 lat do <3 lat. Strefa zagrożenia: $DP \leq 200$ (IEEE) — papier pęka przy zwarcu.

Starzenie termiczne wg IEEE C57.91 — drugi filar oceny żywotności obok DGA. Model opisuje tempo zużycia izolacji jako funkcję temperatury hotspot uzwojenia: przy 110°C izolacja starzeje się z prędkością nominalną (1× aging rate), przy 120°C — ~2× szybciej, przy 130°C — ~4× szybciej. Kluczowe zastosowanie: gdy operator musi obciążyć transformator powyżej normy (np. wyłączenie sąsiedniej jednostki), model C57.91 mówi ile godzin żywotności „zużyje” to przeciążenie. AI integruje model termiczny z prognozą obciążenia i pogodą — dając prescriptive odpowiedź: „możesz obciążyć o 120% przez 6 godzin, koszt = 3 dni żywotności; przy 140% = 45 dni żywotności”.

Jakość oleju (OQI) i wilgotność — trzeci filar, obok DGA i modelu termicznego. Kwasowość oleju (Total Acid Number, TAN), napięcie przebicia (Breakdown Voltage, BDV), rezystywność i kolor degradują z wiekiem oleju i wskazują na konieczność regeneracji lub wymiany. Wilgotność oleju (ppm H_2O) jest jednym z najsilniejszych predyktorów — sam raport wspomina, że 1%→3% wody dramatycznie przyspiesza degradację, ale bez ciągłego monitoringu nie wiesz kiedy próg został przekroczony. Czujniki wilgotności online (Vaisala MHT410, GE Kelman Moisture-in-Oil) kosztują €2–5K i dają pomiar co minutę. To jest inwestycja, która się zwraca z pierwszego unikniętego przeciążenia w mokrym transformatorze.

DGA — badanie krwi transformatora. Dissolved Gas Analysis to jak badanie krwi pacjenta: nie mówi ci dokładnie co boli, ale mówi że coś jest nie tak — i daje wskazówki, gdzie szukać. Gazy rozpuszczone w oleju transformatorowym powstają z rozkładu termicznego oleju i celulozy w różnych temperaturach:

- **H₂** (wodór) → wyładowania niezupełne, korona — to jak kaszel u pacjenta, pierwszy sygnał
- **CH₄** i **C₂H₆** (metan, etan) → przegrzanie niskotemperaturowe (150–300°C) — stan podgorączkowy
- **C₂H₄** (etylen) → przegrzanie wysokotemperaturowe (300–700°C) — gorączka
- **C₂H₂** (acetylen) → łuk elektryczny (>700°C) — to jest alarm, natychmiastowa interwencja
- **CO** i **CO₂** → degradacja celulozy — papier się rozkłada, żywotność ucieka

Problem z klasycznymi metodami interpretacji (trójkąt Duvala, stosunki Rogersa, IEC 60599) polega na tym, że **często dają rozbieżne diagnozy dla tej samej próbki**. Inżynier patrzy na ten sam zestaw gazów i dostaje trzy różne odpowiedzi w zależności od metody. Tu wchodzi ML.

Modele ML na danych DGA — benchmarki dokładności (od najslabszego do najlepszego):

Model	Dokładność	F1	Źródło
Random Forest (4-klasowa)	~89%	0,847	PMC 2024
SHAP-BES-LGBM (optym. cech)	95,09%	0,961	Energy Informatics 2025
1D-CNN z optymalizacją GWO (7-klasowa Duval)	98,39%	~0,98	Arabian J. Sci. Eng. 2025
CNN-LSTM multimodalny z dynamiczną wieloskalową uwagą	99,17%	0,971	IET Electric Power Appl. 2025

Najnowszy model (Tamakloe 2025) łączy CNN (cechy przestrzenne z wielu sensorów) z LSTM (trendy czasowe) i mechanizmem uwagi na wielu skalach. 99,17% dokładności brzmi niemal za dobrze — ale warto zauważyć, że to wynik na zbiorze benchmarkowym. Rzeczywistość produkcyjna z zaszumionymi danymi, brakującymi odczytami i dryftem sensorów będzie mniej czysta. Mimo to, nawet 93–95% w produkcji to ogromny skok wobec 70–80% klasycznych metod interpretacyjnych.

Monitory online DGA nowej generacji eliminują konieczność pobierania próbek oleju do laboratorium:

- **Kelman DGA 900** (GE Vernova): 9 gazów, spektroskopia fotoakustyczna (PAS), pomiar co godzinę z trybem „rapid” dla szybko rozwijających się usterek. Model DGA 900 PLUS dodaje monitoring przepustów (C₁, tan δ), wyładowań niezupełnych i przełącznika zaczepów — pełen obraz zdrowia transformatora z jednego urządzenia.
- **Serveron TM8** (Qualitrol): 8 gazów, chromatografia gazowa laboratoryjnej jakości, pomiar co 4 godziny (do 1/godz. w trybie alarmowym).

Predykcja RUL transformatorów osiąga wyniki, które jeszcze 5 lat temu wydawałyby się nierealne: hybrydowy model Autoencoder-GBR (IEEE Access 2025) uzyskał R² = 0,9946 i RMSE = 1,302 dla predykcji Remaining Useful Life. Schneider EcoStruxure deklaruje predykcję do 6 miesięcy naprzód dla wyposażenia wirującego (przez partnerstwo z Semiotic Labs/SAM4 — analiza sygnałów elektrycznych silnika zamiast wibracji, co eliminuje konieczność montażu dodatkowych czujników).

Kryzys łańcucha dostaw — kontekst, który czyni PdM koniecznością, nie opcją:

Transformator >100 MVA kosztuje \$3–5 mln (wzrost 60–80% od 2020). Czas realizacji: 80–210 tygodni. W USA istnieje zaledwie ~10 wagonów kolejowych zdolnych przewieźć urządzenie ważące 150–400 ton. Hitachi Energy inwestuje \$500 mln w moce produkcyjne w Ameryce Północnej do 2027. Koszt całkowity katastrofalnej awarii (sprzęt + wymiana + ENS + środowisko + kary regulacyjne) sięga \$5–15 mln.

W Polsce problem jest co najmniej równie ostry. Europejska infrastruktura sieciowa — w tym polska — jest jedną z najstarszych na świecie: 40% ma ponad 40 lat. PSE planuje budowę 5 tys. km nowych linii 400 kV i modernizację ponad 100 stacji do 2036. To oznacza, że każdy istniejący transformator, który uda się utrzymać przy życiu dzięki PdM, jest na wagę złota — bo nowego nie ma skąd wziąć szybko.

Key insight: Transformator to aktywo, którego nie da się szybko wymienić. DGA z ML ($F1 > 0,95$) wykrywa degradację miesiące przed awarią. Ale nawet najlepszy model nie pomoże, jeśli nie masz danych — a 65% budżetów AI w energetyce idzie na inżynierię danych, zanim jeszcze model zobaczy pierwszą próbkę.

A2. Turbiny wiatrowe — gdzie wibracje mówią więcej niż SCADA

Turbiny offshore generują ~4,8 zdarzeń serwisowych na turbinę-rok, z czego ~1,5–2 to awarie wymagające naprawy (reszta to resety, inspekcje, drobne regulacje). 76% awarii skrzyni biegów dotyczy łożysk (NREL GRD). EPRI prognozuje 30–70% kumulatywnego prawdopodobieństwa awarii gearboxu w ciągu 20 lat. Przy 20–25 łożyskach w gearboxie i projektowej trwałości $L_{10} = 20$ lat, prawdopodobieństwo awarii przynajmniej jednego łożyska w 20 lat wynosi ~93%. W 7 lat — ~37%. To nie jest pytanie CZY — to jest pytanie KIEDY.

Czujniki wibracji — trzy kategorie, trzy zastosowania:

Akcelerometry piezoelektryczne IEPE (PCB Piezotronics, Brüel & Kjær) — standard przemysłowy. Zakres częstotliwości 0,5 Hz – 30 kHz, czułość 100 mV/g, zakres dynamiczny >120 dB. Montaż magnetyczny lub gwintowany. Doskonałe do gearboxu i generatora, gdzie częstotliwości defektów leżą w zakresie kilkuset Hz do kilku kHz.

Akcelerometry MEMS — mierzą od 0 Hz (DC), co jest kluczowe dla głównego łożyska obracającego się z częstotliwością ~0,3 Hz. Ale mają wyższy próg szumu i zakres ograniczony do 1–5 kHz. W praktyce: MEMS na wolnoobrotowe, piezo na szybkoobrotowe.

Sondy wiropływowe (Brüel & Kjær Vibro WT-010) — mierzą bezpośrednio przemieszczenie wału z rozdzielczością sub-mikrometrową. Najdokładniejsze, ale wymagają stałego montażu w gondoli.

Ile to kosztuje — bo o tym nikt nie mówi:

Typ sensora	Cena	Szum ($\mu\text{g}/\sqrt{\text{Hz}}$)	Zakres freq.	Kiedy wybrać
IEPE piezo przemysłowy (PCB, B&K)	€380–2070	0,6–30	0,5 Hz – 30 kHz	Gearbox, generator — najlepszy SNR
MEMS low-end (ADXL335)	€5–12	300	0–550 Hz	Prototypy, masowe IoT
MEMS high-perf (ADcmXL3021)	€150–400	22,5	0 Hz – 10 kHz+	Główne łożysko — JEDYNY na <0,3 Hz
Sonda wiropływowa (B&K WT-010)	\$2K–5K+	sub- μm	0 Hz – 10 kHz	Przemieszczenie wału, stały montaż

Paradoks cenowy: MEMS za €150 robi dziś prawie to samo co piezo za €2000 robił 10 lat temu. Ale „prawie” to nie „dokładnie” — piezo wciąż wygrywa szumem ($0,6$ vs $22 \mu\text{g}/\sqrt{\text{Hz}}$) i pasmem (30 kHz vs 10 kHz).

Praktyczna rekomendacja: **MEMS na główne łożysko + piezo na gearbox i generator** = optimum kosztowe ~€600–2500 per turbina. Przy 100-turbinowej farmie: €60K–€250K za sensorykę — wobec jednej uniknionej awarii gearboxu wartiej €1–3M.

Parametry wibracyjne i ich znaczenie kliniczne:

Prędkość RMS (mm/s) wg ISO 10816/VDI 3834: poniżej $2,8 \text{ mm/s}$ = stan dobry, $2,8\text{--}7,1$ = alarm, $>7,1$ = zagrożenie. Szczytowe przyspieszenie: normalnie $0,1\text{--}0,5 \text{ g}$, alarm $>1,0 \text{ g}$.

Kurtoza jest szczególnie czuła na wczesne uszkodzenia łożysk — i to jest parametr, na który warto zwrócić szczególną uwagę. Zdrowe łożysko generuje sygnał wibracyjny bliski rozkładowi Gaussa: kurtoza ~ 3 . Gdy na bieżni pojawia się pierwszy defekt (pitting, spalling), każde przejście elementu tocznego przez defekt generuje krótki impuls uderzeniowy. Kurtoza skacze do $4\text{--}8$. Ale tu jest paradoks: gdy uszkodzenie się rozprzestrzenia i bieżnia staje się uniformicznie zdegradowana, kurtoza może *spadać* — bo sygnał staje się znów „gładki”, tyle że z wyższą energią. Dlatego kurtoza działa najlepiej we wczesnych stadiach, a potem trzeba patrzeć na inne wskaźniki.

Częstotliwości defektów łożysk — to jest fundament, bez którego analiza wibracyjna jest ślepa:

- **BPFO** (Ball Pass Frequency Outer) = $(N_b/2) \times [1 - (B^d/P^d) \times \cos(\phi)] \times f_r$ — defekt bieżni zewnętrznej
- **BPFI** (Ball Pass Frequency Inner) = $(N_b/2) \times [1 + (B^d/P^d) \times \cos(\phi)] \times f_r$ — defekt bieżni wewnętrznej
- **BSF** (Ball Spin Frequency) — defekt elementu tocznego
- **FTF** (Fundamental Train Frequency) — defekt koszyka

Gdzie: N_b = liczba elementów tocznych, B^d = średnica elementu tocznego, P^d = średnica podziałowa łożyska, ϕ = kąt styku, f_r = częstotliwość obrotowa wału.

Dla głównego łożyska turbiny (np. SKF 240/630ECJ przy $f_r = 0,39 \text{ Hz}$): BPFO $\approx 4,93 \text{ Hz}$. To jest bardzo niska częstotliwość — dlatego potrzebujesz czujnika MEMS mierzącego od 0 Hz , albo zaawansowanej analizy obwiedni (envelope analysis).

Analiza obwiedni to najskuteczniejsza technika wczesnego wykrywania defektów łożysk. Izoluje repetycję impulsów uderzeniowych z nośnej o częstotliwości rezonansowej struktury ($1\text{--}10 \text{ kHz}$), produkując czyste piki przy BPFO/BPFI w widmie obwiedni. Bez analizy obwiedni, te słabe impulsy toną w szumie innych źródeł wibracji.

Modele ML/DL na danych wibracyjnych — co działa w produkcji:

CNN na scalogramach CWT (Continuous Wavelet Transform) z architekturą ECMCTP (równoległy CNN + Transformer) łączy głębokie cechy częstotliwościowe z zależnościami temporalnymi. Autoencodery na danych wibracyjnych osiągają $F1 = 0,99$ (precision $1,00$, recall $0,98$). LSTM-Autoencoder na zbiorze IMS: $F1 = 99,6\%$. Ensemble VAE + LSTM-AE + Transformer na zbiorze CARE (3 farmy wiatrowe): AUC-ROC = $0,947$.

Turnbull et al. (Wind Energy 2021) wykazał coś ważnego: fuzja danych SCADA i wibracyjnych (klasyfikator one-class SVM na rezydualach Normal Behavior Model) wykrywa anomalie bardziej konsekwentnie niż którekolwiek źródło osobno. SCADA daje kontekst operacyjny (wiatr, obroty, moc), wibracje dają diagnozę mechaniczną. Razem: $1+1 = 3$. **Dokładność predykcji per horyzont czasowy — serce sprawy:**

Ta tabela pokazuje coś, co większość raportów branżowych pomija: predykcja nie jest binarna (działa / nie działa). Dokładność spada z horyzontem — F1 typowo traci 5–8 punktów procentowych na każdy podwojony horyzont. *Wartości poniżej to szacunki autorskie oparte na meta-analizie ~30 publikacji (IEEE Trans. Ind. Inf., Mech. Syst. Signal Proc., Energies MDPI, 2021–2025) — nie pochodzą z jednego badania. Traktuj jako orientację, nie benchmark.*

Aktywo	Algorytm	1 tydzień	1 miesiąc	3 miesiące	6+ miesięcy
Łożysko turbiny (wibracje)	LSTM-AE envelope	F1=0,99	F1=0,96	F1=0,91	F1=0,82
Gearbox (SCADA+wibracje)	Fuzja SVM+NBM	AUC=0,98	AUC=0,94	AUC=0,88	AUC=0,78
Transformator (DGA)	CNN-LSTM multimod.	F1=0,97	F1=0,95	F1=0,91	F1=0,86
Transformator (RUL DP)	Hybrid AE-GBR	—	—	R ² =0,99	R ² =0,97
Inwerter solarny	IF + LSTM	F1=0,95	F1=0,89	F1=0,82	F1=0,74

Co z tego wynika praktycznie? Dla łożysk wibracyjnych masz komfortowe 3–12 miesięcy wyprzedzenia z AUC >0,85. Dla transformatorów DGA: 6+ miesięcy z F1 >0,86. Dla inwerterów solarnych: powyżej 3 miesięcy predykcja staje się zbyt niepewna przy obecnych modelach. To jest granica, którą trzeba znać — żeby nie obiecywać klientowi czegoś, czego technologia jeszcze nie dostarcza.

Brüel & Kjær Vibro — lider rynku z 30 000+ jednostkami DDAU zainstalowanymi od 2003, monitorującymi >150 mln godzin pracy turbin. Wyemitowali 375+ raportów o wysokiej ważności, zapobiegając poważnym awariom. Oferują CMSaaS (monitoring jako usługa) z certyfikowanymi diagnostami ISO 18436.

Koszty wymiany offshore — dlaczego PdM się opłaca:

€1–3 mln za gearbox to nie abstrakcja. To sam komponent (\$200–500K) plus statek jack-up za \$220K/dzień razy 3–7 dni, plus opóźnienia pogodowe (bo morze nie współpracuje z harmonogramem), plus utracona produkcja. Główne łożysko: \$300K–\$700K+. Łopata 107+ metrów: \$500K–\$2 mln. A wczesne wykrycie degradacji łożyska pozwala na naprawę up-tower za \$15K–\$70K zamiast pełnej wymiany gearboxu. ROI jednego trafionego alarmu: **25–120:1**.

SHM łopat wykorzystuje czujniki emisji akustycznej (100 kHz – 1 MHz), sensory FBG na światłowodach (48+ FBG na jednym włóknie, rozdzielczość 1 µε przy 1 kHz — PhotonFirst), LiDAR do monitoringu ugięcia i drony z CV. SkySpecs inspektuje 25 turbin/dzień w Ørsted Teesside (vs. 1/dzień z dostępu linowego). Sulzer Schmid 3DX obsługuje 350+ turbin/sezon. eSmart Systems deklaruje ~99% dokładności detekcji uszkodzeń.

Key insight: Wibracje to najwcześniejszy i najdokładniejszy sygnał degradacji mechanicznej. Kurtoza łożyska skacze 3–12 miesięcy przed awarią. Fuzja SCADA + wibracje > każde źródło osobno. Ale dokładność spada z horyzontem — bądź uczciwy wobec klienta, ile naprawdę „widzi” model.

A3. Panele PV i inwertery — skala wymaga automatyzacji

Farma solarna 100 MW to setki tysięcy paneli rozciągniętych na dziesiątkach hektarów. Ręczna inspekcja takiej farmy to 2500 godzin ludzkiej pracy — ponad rok pracy jednego człowieka. Dron z kamerą

termowizyjną robi to w 10 godzin. Matematyka jest brutalna i jednoznaczna.

Pięć głównych mechanizmów degradacji PV:

PID (Potential Induced Degradation) — migracja jonów Na^+ ze szkła sodowo-wapniowego przez EVA do powierzchni ogniwa tworzy ścieżki boczniowe. Straty mocy: średnio 25%, do 49,6% w ciężkich przypadkach. To nie jest drobnostka — to prawie połowa mocy panelu.

Hotspoty — powstają przy niedopasowaniu ogniw, zacieleniu lub awarii diody obejściowej. ΔT sięga 10–20°C nad otoczeniem, a w ekstremalnych przypadkach >150°C — z realnym ryzykiem pożaru.

Mikropęknięcia — wykrywalne przez elektroluminescencję (EL), powodują izolację fragmentów ogniw. Straty ~0,12%/rok — mało, ale kumulują się.

Degradacja EVA — UV generuje kwas octowy korozyjny dla metalizacji. Żółknięcie, spadek transmitancji.

Snail trails — brązowe smugi nad mikropęknięciami, nanocząstki Ag reagujące z O_2/CO_2 /wilgocią. Straty mocy 12–40% w dotkniętych modułach.

Inspekcja dronowa z AI — nowy standard branżowy:

Raptor Maps zarządza 80+ mln paneli na 6 kontynentach. Wydajność: 10 MW/godzinę lotu. Koszt: \$300–500/MW (vs. manualna inspekcja: \$1500–3000/MW). CNN na termogramach: precision 92%, recall 95%, F1 = 93%. Drony wykrywają 48% więcej problemów niż inspekcje naziemne. ROI inspekcji dronowej: 200–400% w pierwszym roku.

Argonne National Lab — głębszy wgląd:

Zespół dr Feng Qiu (Advanced Grid Modeling) opracował coś, co wyróżnia ich podejście od reszty: modele AI optymalizujące na poziomie **całej sieci** (grid-level), nie pojedynczych aktywów. System estymuje health aktywa, predykuje ryzyko awarii i adaptuje decyzje utrzymania na podstawie bieżących danych polowych. Kluczowe przejście: z modeli laboratoryjnych do danych polowych. Wyniki na inwerterach solarnych: 43–56% redukcji kosztów utrzymania, 60–66% mniej zbędnych wizyt serwisowych, 3–4% wzrostu zysku z instalacji. „Naszym celem jest wyposażenie dostawców energii w narzędzia potrzebne do zapewnienia niezawodnej i odpornej sieci na lata” — dr Qiu.

Key insight: PV PdM to przede wszystkim problem skali. Na farmie 100 MW masz setki tysięcy paneli i tysiące stringów — człowiek tego nie ogarnie. Drony + AI to nie luxury, to konieczność operacyjna. Argonne Lab pokazał, że optymalizacja na poziomie sieci (nie pojedynczego aktywa) przynosi najwyższy ROI.

A4. Linie przesyłowe i kable — niewidoczny wróg pod ziemią i nad głową

100 000 km. Tyle mniej więcej linii wysokiego napięcia ma Polska. Każdy kilometr to przewody wiszące na słupach od 30–50 lat, narażone na wiatr, lód, korozję i drzewa rosnące w stronę przewodu z prędkością metra rocznie. A pod ziemią — kable, w których izolacja degraduje powoli i cicho, aż nagle przestaje izolować. Problem z liniami i kablami jest taki, że nie możesz ich otworzyć i zajrzeć do środka tak jak transformator. Musisz słuchać — elektrycznie, optycznie, satelitarnie.

Dynamic Line Rating — paradoks: linia ma więcej pojemności niż myślisz.

Oto zaskoczenie: typowa linia przesyłowa pracuje przez 95% czasu poniżej swojej rzeczywistej pojemności. Ratingi statyczne (obliczone dla najgorszego przypadku: bezwietrzna noc, 40°C) są konserwatywne o 30–

40%. DLR (Dynamic Line Rating) mierzy rzeczywiste warunki — temperaturę przewodu, prędkość wiatru, nasłonecznienie — i oblicza ile prądu linia NAPRAWDĘ może nieść w tej chwili. To jak różnica między prędkością maksymalną auta wg instrukcji a prędkością, którą możesz bezpiecznie osiągnąć na pustej autostradzie w idealnych warunkach.

Dwóch graczy dominuje rynek DLR — i robią to zupełnie inaczej:

LineVision (Boston) — jedyny bezkontaktowy sensor na rynku. Ich LUX™ montuje się na słupie, nie na przewodzie — bez wyłączni, bez helikoptera, montaż ręczny. Mierzy ugięcie przewodu optycznie (LiDAR) i przelicza na temperaturę i obciążalność. Moduł LineHealth tworzy cyfrowego bliźniaka przewodu: analizuje starzenie termiczne, utratę wytrzymałości na rozciąganie, prognozuje koniec życia. Wdrożenia: National Grid (4 linie 115 kV w Nowym Jorku — największa operacjonalizacja DLR w USA), Xcel Energy, NV Energy.

Ampacimon (Belgia) — mierzy drgania przewodu z dokładnością ugięcia ≤ 1 mm. Podejście: fizyka mechaniczna (częstotliwość drgań struny zależy od napięcia, napięcie zależy od temperatury). Montaż na przewodzie — wymaga wyłączenia. PPL Electric jako pierwsza utility w USA zintegrowała Ampacimon DLR z operacjami rynkowymi: 16% więcej przepustowości przesyłowej.

Case study z ROI: Viesgo (Hiszpania) wdrożył DLR na liniach z dużym curtailmentem wiatrowym. Wynik: uniknięto 4100 godzin curtailmentu i odblokowano 70,9 GWh dodatkowej energii odnawialnej. Przy cenie hurtowej $\sim \text{€}50/\text{MWh}$ to **€3,5 mln** odblokowanej wartości — z inwestycji w sensory kosztującej ułamek tej kwoty.

PdM kabli podziemnych — słuchanie izolacji.

Kabel podziemny to zamknięte pudełko. Nie widzisz co się dzieje wewnątrz izolacji XLPE. Ale możesz SŁUCHAĆ — wyładowania niezupełne (partial discharge, PD) to elektryczny szept degradującej izolacji. Każdy mikro-przebieg w kawernie lub na granicy faz generuje impuls elektromagnetyczny o częstotliwości 100+ MHz. Czujniki HFCT (High Frequency Current Transformer) na mufach kablowych wykrywają te impulsy online, w czasie pracy kabla.

Drugi narzędzie: **$\tan \delta$** (tangens kąta strat) wg IEEE 400.2. To miara „nieszczelności” izolacji — ile energii kabel traci jako ciepło zamiast przewodzić. Średnie $\tan \delta > 50 \times 10^{-4}$ = „wysokie ryzyko”, $\text{tip-up} > 80 \times 10^{-4}$ = wymagana interwencja. AI integruje DWT (Discrete Wavelet Transform) do odsumowania sygnałów PD i deep learning do klasyfikacji wzorców — rozróżniania prawdziwych PD od szumu zewnętrznego (co jest głównym problemem produkcyjnym: fałszywe alarmy z zakłóceń elektromagnetycznych).

Zarządzanie roślinnością z AI — \$24 mld rocznie na przycinanie drzew.

To jest rozmiar problemu: amerykańskie utility wydają \$24 mld rocznie na vegetation management.

Tradycyjna metoda: ekipy terenowe jeżdżą wzdłuż linii, patrzą na drzewa, decydują co ciąć. Jest wolna, droga i nieoptymalna — bo ludzie nie widzą z ziemi tego, co widzi satelita z orbity.

AiDASH obsługuje 800 000+ mil linii w 48 stanach dla 185+ utility. Przewiduje tempo wzrostu na poziomie pojedynczych drzew z dokładnością $> 95\%$ (walidacja Tulane University). Nova Scotia Power: 80% dokładne dopasowanie do ocen terenowych na 28 000 km linii. **Overstory** (Amsterdam, \$43 mln Series B 2025) monitoruje 2 mln+ akrów dla 40+ utility, w tym PG&E — z modelem detekcji paliw pożarowych (krytyczne po pożarach w Kalifornii). **Hitachi Energy + AWS** (SCA marzec 2025): Hitachi Vegetation Manager na chmurze AWS z obrazowaniem satelitarnym Maxar i danymi termicznymi OroraTech.

Uczciwe napięcie: satelitarna VM działa doskonale dla linii napowietrznych w terenie otwartym. W gęstej zabudowie miejskiej i terenach leśnych z koroną pokrywającą przewody — dokładność spada. Fuzja SAR +

LiDAR dronowy + satelita to przyszłość, ale jest droższa i wolniejsza niż czysto satelitarny model.

Key insight: Linie i kable to aktywa, których nie możesz otworzyć i obejrzeć. DLR odblokowuje 30–40% ukrytej pojemności bez budowy nowych linii — ROI liczone w milionach euro z unikniętego curtailmentu. PD monitoring kabli to jedyny sposób na usłyszenie degradacji izolacji, zanim stanie się przebiciem. A \$24 mld/rok na przycinanie drzew to budżet, który AI z satelitów może zredukować o 25–40%.

A5. Infrastruktura stacyjna — ciche awarie najdroższego pomieszczenia w sieci

Stacja elektroenergetyczna to najbardziej skoncentrowany punkt ryzyka w całym systemie. Na kilkuset metrach kwadratowych stoi sprzęt wart \$20–50 mln: transformatory, wyłączniki, odłączniki, przekładniki, baterie stacyjne. Awaria jednego komponentu może wyłączyć z pracy całe pole — a kaskadowo zagrozić stabilności sieci. I tu jest problem: wyłączniki, najważniejsze urządzenia ochronne w stacji, pochłaniają **ponad 40% kosztów utrzymania** całej stacji, a jednocześnie degradują po cichu, między inspekcjami.

Wyłączniki SF₆ — paradoks "zdrowego" wyłącznika:

Wyobraź sobie wyłącznik zrewidowany w standardowym cyklu 3- lub 6-letnim. Inspekcja: „stan dobry, do dalszej eksploatacji”. Cztery miesiące później w cewce wyłączającej rozwija się anomalia prądu — coil current waveform deformuje się, wskazując na tarcie mechanizmu. W ósmym miesiącu wyłącznik będzie niezdolny do wyłączenia prądu zwarcowego w wymaganym czasie. Ale żadna zaplanowana inspekcja tego nie zobaczy — bo następna jest za dwa i pół roku. A w międzyczasie, jeśli nastąpi zwarcie na linii, wyłącznik nie zadziała i awaria kaskaduje na sąsiednie pole.

CIGRE potwierdza: **>50% poważnych awarii wyłączników** wynika z problemów z mechanizmem napędowym — nie z komorą gaszeniową, nie z izolatorem, ale z mechaniki. Sprężyny, zapadki, cewki, tłumiki — elementy, które degradują przez wibracje, temperaturę i zwykłe zmęczenie materiału.

Co monitorujemy i jak:

Monitoring online wyłącznika obejmuje cztery warstwy:

1. **Czasy łączeniowe** — czas od podania impulsu na cewkę do zetknięcia/rozwarcia styków. Rejestrowane przy każdej operacji. Wydłużenie o >10% ponad fabryczne = mechanizm degraduje. Systemy: Franklin Grid INCON Optimizer3, SEL (Schweitzer Engineering Labs) — parsują rekordy COMTRADE z przekaźników ochronnych.
2. **Kumulatywne I²t** — suma energii przerywanych prądów zwarcowych. Każde przerwanie łuku elektrycznego eroduje styki. Wyłącznik ma budżet operacyjny: np. 34 operacje przy 75% prądu znamionowego. Monitorowanie kumulatywnego zużycia styków daje precyzyjny RUL.
3. **Monitoring SF₆** — gęstość (z kompensacją temperaturową), wilgotność, produkty rozkładu (SO₂, SOF₂, HF). Wycieki SF₆ odpowiadają za **40–50% drobnych awarii GIS**. Ciągły monitoring zapobiega do 90% zdarzeń serwisowych. A SF₆ ma GWP = 23 500× CO₂ — każdy wyciek to problem nie tylko techniczny, ale środowiskowy.
4. **Termowizja i wyładowania niezupełne** — IR scanning wykrywa luźne połączenia (przyczyna >30% awarii wyłączników — wykrywalnych tygodnie wcześniej). PD monitoring wykrywa degradację izolacji.

ML na wyłącznikach — co działa:

Trzy podejścia AI udowodnione na danych produkcyjnych:

- **Fuzzy logic expert systems** — trzy podsystemy oceniające niezależnie: stan styków, jakość gazu,

kondycję mechanizmu. Suma = prawdopodobieństwo awarii + priorytet interwencji. Nie wymaga dużych zbiorów treningowych — opiera się na wiedzy eksperckiej.

- **K-means clustering** — nienadzorowany ML klasyfikujący flotę wyłączników w grupy o podobnym ryzyku. Bez wiedzy eksperckiej — czysto z danych monitoringowych. Identyfikuje „czarne owce” w flocie.
- **ANN (sztuczne sieci neuronowe)** — predykcja end-of-life i przyspieszonego starzenia. Na danych z monitoringu + historia operacji + parametry środowiskowe.

Monitoring online redukuje koszty utrzymania wyłączników o **do 30%** i koszty zarządzania częściami zamiennymi o **15%**.

Przejście na SF₆-free — dlaczego AI jest kluczowe:

Siemens Energy Blue Portfolio (izolacja powietrzem, GWP = 0): 2000. jednostka 8VM1 trafiła do offshore Hornsea 3. Projekt LIFE Blue 420 kV GIS (z Elia, Belgia, 2024–2028) — pierwsza demonstracja GIS 420 kV bez F-gazów. ABB AirPlus (~85% suche powietrze + ~15% Novec 5110, GWP < 1): 4000+ zainstalowanych jednostek.

Przejście na SF₆-free oznacza nowe materiały, nowe tryby degradacji, nowe dane. Modele ML wytrenowane na dekadach danych z SF₆ nie przenoszą się bezpośrednio na nowe media izolacyjne. To jest otwarte napięcie: kto pierwszy zbuduje bazę danych awaryjnych dla SF₆-free GIS, ten będzie miał przewagę w PdM nowej generacji rozdzielnic.

Cyfrowa stacja IEC 61850:

Standard IEC 61850 transformuje dostępność danych: Sampled Values (256 próbek/cykl) digitalizują pomiary, GOOSE zapewnia komunikację z opóźnieniem ~2 ms, IEC 61850-90-3 adresuje monitoring stanu. AEP (American Electric Power) wdrożył real-time diagnostykę zdrowia wyłączników na bazie parsingu COMTRADE. Siemens Noedra Node monitoruje całą stację — transformatory, rozdzielnice, systemy ochrony — z jednej platformy.

Key insight: Wyłącznik to strażnik sieci — gdy zawiedzie, awaria kaskaduje. A >50% awarii pochodzi z mechanizmu, który degraduje po cichu między inspekcjami 3/6-letnich. Monitoring online czterech warstw (czasy, I²t, SF₆, termowizja) to \$30–80K per wyłącznik — wobec \$100K–\$1M kosztu awaryjnego. Przejście na SF₆-free generuje nowe napięcie: brak historycznych danych awaryjnych dla nowych mediów izolacyjnych.

B. Architektura danych i algorytmy ML/DL

B1. Pipeline danych — od sensora do decyzji

Rys. 2 — Pełny pipeline PdM z podziałem na domeny: OT (sensor, edge), Data Engineering (data lake, features), AI/ML (model, alert), Business (CMMS, feedback). Retrain loop zamyka pętlę.

Typowy pipeline PdM: **sensor → bramka edge → historyk/data lake → inżynieria cech → model → alert → CMMS**. Brzmi prosto. W praktyce każdy z tych kroków to pole minowe.

Przetwarzanie edge redukuje wolumen transmitowanych danych o >90%. Pojedynczy czujnik wibracji przy 50 kHz generuje ~3,6 GB/dzień surowych danych; edge kompresuje to do kluczowych cech. Opóźnienie edge:

<50 ms vs. 200 ms+ dla chmury.

AVEVA PI System (dawniej OSIsoft) dominuje: 80% największych firm O&G i 65% przemysłowego Fortune 500. Kompresja algorytmem Swinging Door Trending (SDT) osiąga stosunek 10:1 do 100:1 przy zachowaniu wierności danych. PI Integrator eksportuje dane do AWS S3/SageMaker, Azure Event Hubs lub data lake.

Minimalne częstotliwości próbkowania — to trzeba znać zanim kupisz sensory: wibracje łożysk 20–50 kHz; DGA transformatorów co 1–4 godziny (online); SCADA turbin 1 Hz surowe, 10-min średnie standardowe; temperatura 1–60 s; wyładowania niezupełne 100+ MHz.

Key insight: AVEVA PI jest w energetyce tym, czym Excel w finansach — wszędzie i często nadużywany. Kompresja SDT 100:1 traci surowe wibracje — a to właśnie te dane karmią modele ML. Pipeline danych PdM wymaga świadomej decyzji: co kompresować (temperatura = OK), a co zachować w pełnej rozdzielczości (wibracje = nie kompresuj).

B2. Algorytmy — co naprawdę działa w produkcji

Uwaga: większość papierów naukowych raportuje wyniki na zbiorach benchmarkowych (CWRU, IMS, CMAPSS). Rzeczywistość produkcyjna jest mniej czysta — zaszumione dane, missing values, dryft sensorów, zmienne warunki operacyjne. Wyniki w produkcji są typowo 5–15 punktów procentowych niższe niż na benchmarkach.

Physics-Informed Neural Networks (PINN) osadzają równania fizyczne w funkcji straty: strata = strata_danych + strata_fizyczna. Przewaga: lepsza ekstrapolacja, 2,5× szybszy trening, fizycznie spójne predykcje przy rzadkich danych. Konkretnie wdrożenie: PINN z ograniczeniami termodynamicznymi osiągnął MAPE = 1,87% predykcji dyssypacji energii w sieci solarnej 12,4 MWp — o 38% lepiej niż LSTM i 42% lepiej niż XGBoost.

Ramka decyzyjna per typ aktywa — bo nie ma jednego algorytmu na wszystko:

- Maszyny wirujące (łożyska, silniki) → **2D-CNN na scalogramach CWT + LSTM hybrid**
- Turbiny wiatrowe (dane SCADA) → **LSTM/GRU lub Temporal Fusion Transformer**
- Transformatory mocy → **hybrydowy physics-CNN-LSTM lub TFT**
- Turbiny gazowe → **TFT lub Transformer**
- Magazyny energii → **PINN-LSTM**
- Ogólne dane tabelaryczne → **Random Forest / XGBoost ensemble**

Rys. 3 — Decision tree doboru algorytmu. F1 i AUC: zakres od horyzontu 1 tydzień (najwyższe) do 6+ miesięcy (najniższe). Foundation models (Chronos-2, Granite, Lag-Llama) = demokratyzacja predykcji dla mniejszych utility.

Transfer learning działa w praktyce: pre-trening na danych flotowych uczy ogólnych wzorców degradacji, fine-tuning na danych lokalnych. GE Vernova wybrał ONYX Insight jako jedynego dostawcę CMS dla 7000+ turbin onshore. PSR-CNN-DLSTM z transfer learningiem (2025) generalizuje między warunkami operacyjnymi.

Federated learning między utility testowany operacyjnie: CR-FL z regularyzacją FedProx osiąga wyższą precision niż scentralizowany LightGBM na danych SCADA turbin. Wyzwanie: heterogeniczność danych (non-

IID) — turbiny w różnych lokalizacjach doświadczają różnych warunków.

Foundation models to najnowszy trend: Chronos-2 (Amazon) — 20M–710M parametrów, 300+ prognoz/sek na jednym GPU. Lag-Llama (ServiceNow) — decoder-only, pełne rozkłady prawdopodobieństwa z przedziałami niepewności, open-source. Granite Timeseries (IBM) — zintegrowane z watsonx.ai, zero-shot forecasting dla IoT.

False positives — problem, który niszczy zaufanie:

Systemy PdM generują typowo 5–15% fałszywych alarmów bez optymalizacji. Ekipa serwisowa jedzie na obiekt, nie znajduje usterki, traci zaufanie do systemu, zaczyna ignorować alerty. Cel: <5% FPR. Siedem technik: adaptacyjne progi z ROC, pipeline ensemble IF+AE, filtrowanie temporalnej persystencji, wielopoziomowe alerty, cost-sensitive loss functions, transfer learning z floty, human-in-the-loop z SHAP/LIME. W praktyce najskuteczniejszy jest pipeline dwufazowy: Isolation Forest do szybkiego screeningu, Autoencoder do potwierdzenia.

Key insight: Nie ma jednego algorytmu na wszystko. Maszyny wirujące → CNN-LSTM na CWT, turbiny → TFT, transformatory → physics-CNN-LSTM. Ale ważniejsze niż wybór algorytmu jest zrozumienie, że 5–15% false positive rate w produkcji niszczy zaufanie ekip serwisowych. Pipeline dwufazowy (IF screening + AE potwierdzenie) to minimum.

B3. Syntetyczne dane awarii — bo prawdziwych jest za mało

Problem jest fundamentalny: jak nauczyć model rozpoznawać awarię, jeśli masz 2 awarie na 1000 transformatorów w 10 lat? Albo 12 awarii gearboxu na 500 turbin w 5 lat? Dane awaryjne w energetyce są ekstremalnie rzadkie — bo infrastruktura jest niezawodna (paradoksalnie to utrudnia budowę modeli predykcyjnych).

Case Study 1 — WGAN-GP dla turbin wiatrowych: Na 500 turbin, dane o awariach gearboxu dostępne dla zaledwie 12 zdarzeń w 5 lat. WGAN-GP wygenerował 2000 syntetycznych sekwencji degradacji. Model ANN na danych augmentowanych: dokładność 89% vs. 67% na samych danych rzeczywistych (+22 pp). To nie jest drobna poprawa — to różnica między użytecznym a bezużytecznym modelem.

Case Study 2 — Modele dyfuzyjne (TLDM 2025): Temporal Latent Diffusion Model z BiGRU generuje syntetyczne trendy degradacji maszyn wirujących. Stabilniejszy trening niż GAN (brak kolapsu modów). Na zbiorze CMAPSS: redukcja RMSE predykcji RUL o 12% przy augmentacji dyfuzyjnej vs. sam LSTM.

Case Study 3 — Cross-system transfer (IEEE BigData 2024): Model dyfuzyjny uczący się relacji zdrowy→uszkodzony z podobnych aktywów generuje syntetyczne dane awaryjne dla systemów, które jeszcze nie uległy awarii. F1 = 0,84 vs. 0,71 bez augmentacji.

Modele dyfuzyjne wyłaniają się jako lepsza alternatywa dla GAN: stabilniejszy trening, wyższa różnorodność próbek, lepsza koherencja temporalna. To jest trend do obserwowania.

Key insight: Syntetyczne dane awaryjne to nie oszustwo — to jedyny sposób na trenowanie modeli w branży, gdzie awarie zdarzają się rzadko. +22 pp dokładności z WGAN-GP na turbinach to przekonujący dowód. Modele dyfuzyjne (2025+) zastępują GAN-y.

C. Platformy vendorów — głębokie porównanie

C1. GE Vernova APM — flota jako fosa

Fundament algorytmiczny: **Similarity-Based Modeling (SBM)** — nieparametryczna technika rozpoznawania wzorców wielozmiennych. Biblioteka referencyjna historycznych snapshotów sensorowych porównywana z danymi real-time przez metrykę podobieństwa. Rezydualne (aktualne – szacowane) analizowane testem Hotellinga T^2 i SPRT. 350+ pre-built blueprintów Digital Twin. Monitoruje >7000 aktywów krytycznych z oszczędnościami >\$1,6 mld.

Nieosiągalna przewaga: flota turbin serwisowanych przez GE Vernova — **~7000 gazowych + ~57 000 wiatrowych** — wytwarza ~25% światowej elektryczności. Transfer learning z tej bazy to fosa, której pure-software vendorzy nie mogą skopiować.

Referencje: Dorad Energy (Izrael, \$4M oszczędności na 12 turbinach LM6000), Total EP (zero niespodziewanych awarii), A2A (Włochy), Xcel Energy (USA).

C2. IBM Maximo MAS 9.1 — jedyne EAM+APM w jednym

Jedyna platforma łącząca pełne zarządzanie aktywami (EAM) z predykcyjnym APM bez middleware'u. Gdy Maximo Health identyfikuje degradację, automatycznie triggeruje zlecenie w Maximo Manage z częściami, pracą i procedurami. 4 gotowe szablony ML: prawdopodobieństwo awarii, RUL, krzywa życia, anomalia. AutoAI automatycznie eksperymentuje z algorytmami. Granite Timeseries do zero-shot forecasting'u IoT. Cena: \$39–65/user/mies., enterprise \$50K–500K+/rok.

C3. AspenTech Mtell — agenci zamiast modeli

Podejście fundamentalnie różne od klasycznego ML. Dwa autonomiczne agenty: **Anomaly Agents** uczą się wzorców normalności; **Failure Agents** fingerprintują konkretne prekursorzy awarii. Generowanie jednym kliknięciem — nie wymaga data scientistów. Agent samodostrajający: jeśli inspekcja ujawni, że zmiana to nowy tryb operacyjny, agent automatycznie się przeucza. Predykcja do 90 dni naprzód. Od I 2026 integracja z Emerson AMS Machine Works.

C4. Schneider EcoStruxure Transformer Expert

Sonda IoT all-in-one w zaworze olejowym: 6 zintegrowanych czujników (3x temperatura, 1x wilgotność, 1x wibracje, 1x PD) + opcjonalny H₂. Transmisja 3G/4G, kalibracja fabryczna, gwarancja dożywotnia przy aktywnej subskrypcji. Connected Services Hub z globalną pulą danych z tysięcy instalacji. CERN: 8 transformatorów monitorowanych.

C5. Hitachi Energy Lumada + Nostradamus AI

Jedyny vendor produkujący aktywa sieciowe (transformatory, wyłączniki, HVDC) i dostarczający platformę APM i oferujący AI prognostyczne. Lumada APM: 3 moduły — Health (real-time, prognostyka), Reliability (dynamiczna ocena ryzyka), Optimization (optymalizacja capex/opex).

Nostradamus AI to algorithm-agnostic engine na ~30 latach danych rynkowych: automatycznie dobiera najlepszy algorytm per problem (ensemble: GBM, LSTM, Bayesian). Trzy domeny: prognozowanie obciążenia, generacji wiatrowej/solarnej i cen. Integracja Lumada+Nostradamus daje unikalny kontekst: „transformator degraduje (Lumada) + nadchodzi fala upałów z rekordowym obciążeniem (Nostradamus) = priorytet krytyczny”. Wieloletnia SCA z AWS (III 2025).

C6. ABB Ability Genix APM

Trzywarstwowa platforma: **EdgeInsight** (bramka OT→IT, <1s latency, konwersja Modbus/Profibus/OPC-UA do jednego standardu) → **Azure cloud** (Genix APM Predict/Health/Optimize) → **Genix APM Copilot** (V 2025, GPT-4 tunowany na danych przemysłowych, agentowe workflow'y z akcjami w systemach trzecich).

Algorytmy: Heuristic Knowledge (FMEA) + Statistical ML hybrid. Dane z healthy state konfiguruja modele, rezydua generuja alerty. Viking Analytics dostarcza AI anomaly detection. No-code config — nie potrzebujesz data scientista.

Hardware: ABB Smart Sensor — retrofit w 15 min (montaz magnetyczny), vibracje 3-osiowe + temperatura + Bluetooth. TRAFCON — monitoring transformatorow agnostyczny wobec producenta, hardware + 3 lata chmury w cenie.

Klienci: Enel Green Power (5 hydro, w tym Presenzano 1000 MW, 190K sygnalow, ~800 modeli), OKEA Draugen (edge real-time). Deklarowane wyniki: do 40% redukcji kosztow O&M, do 30% poprawa efektywnosci, do 25% poprawa efektywnosci energetycznej.

C7. Siemens Sensproducts — podstacja „born connected”

Od 2018 **wszystkie nowe transformatory Siemens Energy** to Sensformery. Sensgear rozszerza koncepcje na GIS i wytlaczniki. Pilotaz Netze BW Burladingen: pierwszy SF6-free GIS 145 kV + Sensformery + cyfrowa magistrala procesowa. Senseye GenAI (2024+): konwersacyjny AI z wielojezycznym rozumowaniem na case'ach serwisowych. Insights Hub — Lider IDC MarketScape IIoT Platforms 2024.

C8. Gracze emergentni

SparkCognition — Ørsted na 5500 MW onshore wind/solar/BESS, jedyny AI purpose-built dla multi-tech renewable portfolio. **Augury** — gwarancja diagnostyczna ubezpieczona przez Munich Re, F1 >99,9%, Machine Health Ultra Low (III 2025) dla maszyn 1–150 RPM. **eSmart Systems** — 75+ utility (Xcel Energy 22 000+ mil), AI Studio (III 2026) do custom computer vision. **C3.ai** — Shell (5200+ urzadzzen), ENGIE, Enel.

Tabela porownawcza vendorow

Rys. 4 — Mapa vendorow. Lewy gorny kwadrant: enterprise multi-asset (GE Vernova, IBM Maximo). Prawy gorny: dostepny multi-asset (ABB Genix, AspenTech). Lewy dolny: enterprise specjalista (Hitachi Lumada). Prawy dolny: dostepny specjalista (SparkCognition, Schneider). Pozycjonowanie: ocena autora, nie ranking jakosci.

Vendor	Algorytm	Deploy	Top referencja	Unikalna cecha
GE Vernova APM	SBM + PCA + SPRT + 350 DT blueprintow	SaaS/On-prem	Dorad (\$4M savings), >\$1,6 mld laczenie	Fleet data moat: 7K turbin gaz. + 57K wiatrowych
IBM Maximo MAS	AutoAI + Granite Timeseries + watsonx GenAI	SaaS/Cloud/On-prem	VPI, nuclear, \$2,3M avoided replacements	Jedyny EAM+APM — predykcja triggeruje zlecenie

AspenTech Mtel	Agent-based: Anomaly + Failure Agents	Cloud/On-prem	YPF, US freight (4250 lokomotyw)	Prescriptive bez data scientistów
Schneider EcoStruxure	IEEE/CIGRÉ + SAM4 + trend/forecasting	SaaS managed	CERN (8 trafo), BASF (63 aktywa)	Hardware+software+eksperci pod klucz
Hitachi Lumada+Nostradamus	Algorithm- agnostic ensemble + physics RCM	SaaS(AWS)/Hybrid	Inner Mongolia Power (20/220 kV RCM)	OEM grid + APM + AI forecasting w jednym
ABB Genix APM	FMEA + Statistical ML + GenAI Copilot GPT-4	Edge+Azure hybrid	Enel Green Power (190K sygnałów, 800 modeli)	No-code + Copilot z akcjami w 3rd-party + Smart Sensor 15 min
Siemens Sensproducts	Physics DT + data-driven + Senseye GenAI	Born connected/SaaS	Netze BW (SF ₆ -free digital substation)	KAŻDY nowy trafo = Sensformer z IoT
SparkCognition	AI+ML + physics DT hybrid	SaaS	Ørsted (5500 MW multi- tech)	Purpose-built wind+solar+BESS+hybrid

Czego vendorzy nie mówią w broszurze

Każdy vendor wygląda świetnie w swoim materiale marketingowym. Ale decyzja zakupowa wymaga uczciwego porównania słabości:

Vendor	Główna słabość	Ryzyko
GE Vernova	Vendor lock-in — modele SBM są proprietary, nie wyeksportujesz danych treningowych do innej platformy. Najlepszy na aktywach GE, słabszy na multi-vendor.	Jeśli zmienisz vendor sprzętu, tracisz wartość platform APM
IBM Maximo	Złożoność wdrożenia: 6–18 mies., TCO enterprise \$200K–\$500K+/rok. Wymaga dedykowanego admina. AutoAI jest potężny ale nie magiczny — garbage in = garbage out.	Małe utility nie stać na Maximo. ROI dopiero po 12–24 mies.
AspenTech Mtel	Black box — agenci uczą się automatycznie, ale nie masz wglądu DLACZEGO model podjął taką decyzję. Problematyczne w kontekście EU AI Act (wymóg explainability).	Audytorzy regulacyjni mogą kwestionować systemy bez wyjaśnialności
Schneider EcoStruxure	Hardware lock-in: sonda IoT działa z platformą Schneider. Subskrypcja obowiązkowa — gwarancja dożywotnia pod warunkiem płacenia. Ograniczone do transformatorów + MV/LV.	Nie pokrywa turbin, GIS, linii — potrzebujesz drugiej platformy

Hitachi Lumada	Najsilniejszy na aktywach Hitachi Energy (trafo, wyłączniki). Na aktywach innych OEM — mniejsza baza referencji. Nostradamus AI = forecasting, nie PdM sensu stricto.	Mylące pozycjonowanie — Nostradamus prognozuje rynek, nie awarie
ABB Genix	GenAI Copilot (GPT-4) = bleeding edge. Ryzyko halucynacji AI w kontekście decyzji operacyjnych o aktywach krytycznych. Genix APM jest stosunkowo nowy vs GE/IBM.	Czy zaufasz GPT-4 z rekomendacją dotyczącą transformatora 100 MVA?
Siemens Sensproducts	„Born connected” = działa najlepiej na NOWYCH aktywach Siemens. Retrofit starszych aktywów innych producentów — Sensformer LITE, ale mniejsza funkcjonalność.	80% floty to istniejące aktywa — „born connected” nie pomaga wstecz

Matryca decyzyjna — szybki filtr

Masz...	Wybierz...	Dlaczego
Flotę turbin GE + budżet enterprise	GE Vernova APM	Nieosiągalna baza danych flotowych, pre-built DT
Multi-vendor aktywa + istniejący SAP/ERP	IBM Maximo MAS	Jedyny EAM+APM, integracja z ERP
Elektrownia procesowa + brak data science	AspenTech Mtell	Agent-based, no-code, prescriptive
Stacje transformatorowe + mały budżet	Schneider EcoStruxure	Pod klucz: hardware + software + eksperci
Aktywa sieciowe Hitachi + potrzeba forecastingu	Hitachi Lumada + Nostradamus	OEM data + forecasting rynku
Istniejąca flota multi-vendor + Azure	ABB Genix	No-code, GenAI Copilot, edge 15 min retrofit
Nowe stacje + cel SF ₆ -free	Siemens Sensproducts	Born connected, cyfrowa stacja od dnia 1
Wind+solar+BESS portfolio	SparkCognition	Jedyny purpose-built dla multi-tech renewables

Key insight: Żaden vendor nie jest najlepszy we wszystkim. GE Vernova ma nieosiągalne dane flotowe — ale vendor lock-in jest realny. IBM Maximo jedyny EAM+APM — ale wdrożenie trwa 6–18 mies. i kosztuje. AspenTech nie wymaga data scientistów — ale jest black-boxem. Wybieraj nie najlepszą platformę, lecz najlepszą dla TWOJEGO miksu aktywów, danych i ludzi.

D. Od Predictive do Prescriptive i Autonomous

D1. Prescriptive maintenance — pełny workflow, krok po kroku

Różnica między predictive a prescriptive jest jak różnica między lekarzem, który mówi „masz problem z sercem” a lekarzem, który mówi „masz problem z sercem, weź ten lek dwa razy dziennie, umów się na kontrolę za miesiąc, oto skierowanie do kardiologa, i zredukuj sól w diecie”. Prescriptive zamyka pętlę od detekcji do działania.

Pełny workflow na przykładzie turbiny wiatrowej offshore — 8 kroków:

Krok 1 — Detekcja (sekundy): Czujnik wibracji na gearboxie wykrywa wzrost kurtozy z 3,2 do 5,8 i harmoniczne BPFO na 47,3 Hz w widmie obwiedni. LSTM-Autoencoder klasyfikuje to jako anomalie (błąd rekonstrukcji $>3\sigma$).

Krok 2 — Diagnoza (minuty): System koreluje wzorzec z bazą fingerprint’ów. Identyfikacja: „early-stage outer race defect, high-speed intermediate shaft bearing” (kod FMEA: GB-HSS-BRG-OR-01). Confidence: 87%. Potwierdzenie: fuzja SCADA (temperatura łożyska $+4^{\circ}\text{C}$) + wibracje + analiza olejowa ($\text{Fe} > 15 \text{ ppm}$).

Krok 3 — Prognoza RUL (sekundy): Model physics-informed (Paris-Erdogan + ML residual): „RUL = 47 ± 12 dni przy obecnym obciążeniu. Przy redukcji obciążenia o 15%: RUL $\rightarrow 68 \pm 15$ dni”.

Krok 4 — Magazyn (sekundy): CMMS/ERP: łożysko SKF 6328 M/C3 — 1 szt. w Rotterdam (3 dni dostawy). Narzędzia: zestaw grzewczy indukcyjny — dostępny. Olej: 200L na stanie.

Krok 5 — Optymalizacja harmonogramu (minuty): Analiza: (a) pogoda — okno Hs $< 1,5\text{m}$ w dniach 18–22, (b) SOV dostępny od dnia 17, (c) niski popyt weekendowy $\rightarrow$ minimalna utrata produkcji, (d) 2 certyfikowanych techników dostępnych. Wynik: optymalny termin = dzień 19 (sobota), margines bezpieczeństwa 28 dni.

Krok 6 — Auto Work Order (sekundy): System generuje zlecenie w CMMS: typ = Corrective Planned, priorytet = High, checklist z biblioteki OEM, części zarezerwowane, ekipa przypisana, szacowany czas = 8h.

Krok 7 — Derating tymczasowy (sekundy): System sugeruje redukcję obciążenia o 15% do naprawy $\rightarrow$ wydłużenie RUL. Operator zatwierdza jednym kliknięciem.

Krok 8 — Feedback loop (po naprawie): Inspekcja potwierdza: outer race pitting, stadium 2. Dane wracają do modelu $\rightarrow$ re-trening. Log: detekcja $\rightarrow$ naprawa = 26 dni, koszt planowanej naprawy = €45K, uniknięty koszt (gearbox + jack-up) = €1,8M. **ROI tego jednego zdarzenia: 40:1.**

To jest moim zdaniem najważniejsza sekcja tego raportu. Bo predictive mówi „coś się popsuje za 47 dni” — i zostawia cię z tą informacją. Prescriptive mówi co zrobić, kiedy, w jakiej kolejności, z jakimi zasobami. To jest różnica między diagnozą a leczeniem.

Kto to robi w produkcji: AspenTech Mtell (pełny prescriptive z auto-WO), GE Vernova SmartSignal + ServiceMax, IBM Maximo Predict $\rightarrow$ Manage. Szacunek McKinsey: $< 10\%$ utility działa na poziomie prescriptive. To jest przyszłość, ale jeszcze nie teraźniejszość.

D2. Autonomous maintenance — drony, roboty i granice regulacji

Autonomiczny dron inspekcyjny to nie science fiction. To jest Florida Power & Light, dziś, 2026 — **Percepto** wdrożył największą komercyjną flotę autonomicznych dronów u amerykańskiej utility. Pełne loty BVLOS (Beyond Visual Line of Sight), bez pilota w pętli, z automatycznym ładowaniem w stacjach dokujących rozstawionych na terenie stacji i farm. Dron startuje na zaplanowaną misję, leci trasę, fotografuje, analizuje, wraca, raportuje. Człowiek widzi wynik, nie lot.

Ale dron to inspekcja — łopaty wciąż trzeba naprawić. I tu wchodzi roboty.

BladeBUG (UK) — sześćcio-nożny robot z przyssawkami próżniowymi, poruszający się po łopatach turbin offshore. Pierwsza robotyczna inspekcja łopaty offshore: X 2020, turbina 7 MW ORE Catapult. Inspekcja w 35 minut (połowa czasu dostępu linowego). Potencjalna redukcja kosztów utrzymania 30–50%. **Aerones** (Łotwa) — obsłużył >300 turbin w 17 krajach robotami do czyszczenia, inspekcji i napraw łopat. Deklarowany wzrost rocznej produkcji energii o 12% z samego czyszczenia (brud na łopatach = utrata aerodynamiki).

Skydio + MEPPI — dron X10 z CV Power-I do inspekcji stacji: redukcja czasu inspekcji słupa z 30 min do 30 sekund. 92% oszczędności czasu.

Poziomy gotowości technologicznej:

Technologia	TRL	Status 2026
Autonomiczne drony inspekcyjne z docking	8–9	Komercyjne (FPL, Xcel Energy)
Roboty inspekcyjne łopat	6–7	Pilotaże komercyjne (BladeBUG, Aerones)
Autonomiczna naprawa łopat (coating, patches)	5–6	Demonstracje laboratoryjne
Pełne autonomiczne utrzymanie bez nadzoru	4–5	Koncepcyjna faza badawcza

Granica nie jest tylko techniczna — jest regulacyjna. **EU AI Act** klasyfikuje AI w infrastrukturze krytycznej jako system high-risk. To oznacza wymóg „meaningful human oversight” (Art. 14): człowiek musi mieć możliwość monitorowania, interweniowania i nadpisania decyzji AI. Pełna autonomia (robot sam decyduje o naprawie bez zatwierdzenia) jest dziś prawnie wątpliwa w Europie. Realistyczny model na najbliższe 5 lat: **human-on-the-loop** — robot proponuje, człowiek zatwierdza.

Key insight: Autonomiczne drony to dziś (TRL 8–9). Roboty łopatuowe za 2–3 lata. Ale „pełna autonomia” w energetyce jest ograniczona regulacyjnie, nie tylko technicznie — EU AI Act wymaga human oversight dla infrastruktury krytycznej. Paradoks: technologia jest gotowa szybciej niż regulacje pozwalają ją wdrożyć.

D3. Digital Twin + Reinforcement Learning — trening bez ryzyka

Cyfrowy bliźniak to nie wizualizacja 3D na ekranie prezesa. To środowisko treningowe dla agentów AI, którzy uczą się optymalnych strategii utrzymania bez ryzykowania fizycznych aktywów wartych miliony. Wyobraź sobie symulatora lotu — piloci uczą się reagować na awarię silnika w symulatorze, zanim usiądą w prawdziwym kokpicie. DT + RL robi to samo dla inżyniera utrzymania.

Jak to działa technicznie:

Agent RL operuje w pętli: **Obserwacja** (stan aktywa z DT: health index, RUL, aktualne obciążenie, prognoza pogody, stan magazynu) → **Akcja** (nie rób nic / monitoruj częściej / ogranicz obciążenie / zaplanuj naprawę / wymień przewencyjnie) → **Nagroda** (koszt przestoju × P(awaria) – koszt interwencji – utracona produkcja). Agent eksploruje tysiące trajektorii, popełnia „błędy” w symulacji (zbyt późna naprawa → symulowana awaria), i uczy się z nich — bez żadnego kosztu fizycznego.

Trzy przełomowe papery:

Liu et al. (2025, Int J Adv Manuf Technol) — DT modeluje problem CBM jako Continuous Semi-Markov Decision Process (CSMDP). Agent uczy się na symulowanych trajektoriach degradacji generowanych przez DT. Kluczowy wynik: **60% redukcja kosztów utrzymania** vs. tradycyjne podejścia multi-objective

optimization. To nie jest marginalna poprawa — to zmiana paradygmatu.

Compare et al. (Renewable Energy, 2021) — agent Deep RL optymalizujący O&M 30-turbinowej farmy wiatrowej offshore. Unikalne podejście: agent NIE zakłada z góry typu strategii (corrective, scheduled, predictive). Sam odkrywa optymalną politykę hybrydową — kiedy naprawiać, kiedy wymieniać, kiedy wysłać statek, kiedy czekać. Przewaga nad klasycznym OR: adaptuje się do zmieniających się warunków w real-time.

iFANnpp (arXiv 2024) — cyfrowy bliźniak elektrowni jądrowej w Unreal Engine 5, zintegrowany z symulatorem GPWR. Pierwszy DT jądrowy zaprojektowany specjalnie pod RL: trening robotów serwisowych w nawigacji po strefach radiacyjnych, optymalizacja harmonogramu inspekcji. Pokazuje, że DT+RL ma zastosowanie nawet w najbardziej regulowanym i niebezpiecznym segmencie energetyki.

DT jako fabryka syntetycznych danych:

DT generuje tysiące trajektorii run-to-failure pod różnymi warunkami (temperatura, obciążenie, wilgotność), produkując dane treningowe dla modeli ML. Na realnej flocie: 2 awarie gearboxu na 500 turbin w 5 lat. W DT: 10 000 syntetycznych awarii w jeden weekend. Modele trenowane na mix syntetyczne + realne: F1 o **8–15 pp wyższe** niż na samych danych rzeczywistych.

Uczciwe napięcie: DT+RL jest wciąż głównie akademicki. Komercyjne wdrożenia w energetyce można policzyć na palcach jednej ręki. GE Vernova ma 350+ blueprintów DT, ale RL na nich — publicznie dostępne dowody ograniczają się do wewnętrznych pilotaży.

Key insight: DT + RL to najelegantsze rozwiązanie problemu „zbyt mało awarii do treningu” — agent uczy się na symulacjach, odkrywa politykę bez a-priori założeń, redukuje koszty o 60%. Ale uczciwie: to wciąż za półmenem między akademią a produkcją. Komercjalizacja = 2027–2029.

E. Ekonomia — koszty awarii i ROI

E1. Koszt katastrofalnej awarii

Aktywo	Koszt bezpośredni	Koszt pośredni	Koszt całkowity
Transformator >100 MVA	\$3–5 mln + transport	ENS + kary regulacyjne	\$5–15 mln
Gearbox offshore	\$200–500K komponent	Jack-up \$220K/dzień × 3–7 dni	\$1–3 mln
Główne łożysko offshore	\$20K–\$300K	Jak gearbox jeśli demontaż gondoli	\$300K–\$3 mln
Łopata 107+ m	\$300–700K	Transport + instalacja + statek	\$500K–\$2 mln
Inwerter centralny 100 MW	\$3–6 mln (fleet)	Utracona produkcja +20–30%	\$4–8 mln

E2. TCO platformy PdM — 5-letni model dla 200 aktywów

Pozycja	Rok 0	Rocznie (1–5)	5-letnie TCO
---------	-------	---------------	--------------

Sensory per aktywo	\$200–\$50K (wibracje–DGA)	Kalibracja	Zależne od miks
Licencje	\$100K–\$300K	\$100K–\$300K/rok	
Integracja	\$25K–\$150K	\$10K–\$30K/rok	
Personel (2–4 FTE)	—	\$200K–\$500K/rok	
Suma	\$200K–\$500K	\$300K–\$830K/rok	\$1,5–4,7 mln
Oszczędności		25–30% redukcja + uniknięte awarie	\$3–10 mln

Platformy hardware-agnostyczne (Factory AI): deployment w 14 dni, ROI w Q1. Enterprise (Maximo, SAP): 6–18 mies. wdrożenia, 12–24 mies. do wartości.

Key insight: ROI PdM różni się drastycznie per typ aktywa. Transformator mocy: **15:1** (\$15K/rok DGA online vs. \$5–15M awaria). Turbina offshore: **25–120:1** (jeden trafiony alarm CMS = \$1–3M unikniętego gearboxu). Onshore: **8–15:1** (bez jack-up). PV portfolio 100 MW: **200–400%** w pierwszym roku (drony + anomaly detection). Wyłącznik HV: **5–10:1** (\$30–80K monitoring vs. \$100K–\$1M awaria). Największy ROI jest offshore (bo koszty awarii astronomiczne). Najszybszy payback w PV (bo drony tanie a straty duże).

F. Bariery i jak je pokonać

F1. Dane pochłaniają 65% budżetu — i to jest normalne

65% budżetów projektów AI w energetyce idzie na inżynierię danych — trzykrotnie więcej niż średnia międzysektorowa (23%, Wood Mackenzie). Gartner (VII 2024): 63% organizacji nie ufa swoim praktykom zarządzania danymi dla AI, a 60% projektów AI pozbawionych AI-ready data zostanie porzuconych do 2026.

W praktyce 60–80% czasu projektu ML schodzi na przygotowanie danych. Dlaczego tak dużo? Bo energetyka ma unikalne problemy:

Silosy OT/IT — SCADA, DCS, historian, ERP, CMMS to osobne systemy, często od różnych vendorów, z różnymi modelami danych. Zaledwie 28% europejskich utility osiągnęło podstawową integrację OT/IT (Siemens Grid Digitalization Benchmark 2025). Reszta ma dane w 5–10 silosach, które nie rozmawiają ze sobą.

Brak standaryzacji tagów — ten sam czujnik temperatury na transformatorze jest oznaczony „TR1_TEMP_OIL” w jednej stacji, „T1.OilTemp” w drugiej, i „XFMR_01_TO” w trzeciej. Bez harmonizacji tagów nie zbudujesz modelu flotowego — a flotowe modele (transfer learning) dają najlepsze wyniki.

Missing values i dryft — czujnik terenowy przy -20°C w styczniu traci kalibrację. Transmisja GSM z odległej stacji ma luki. Historian z kompresją SDT 100:1 traci surowe piki wibracyjne. To nie są wyjątki — to norma.

Data readiness assessment przed wdrożeniem PdM: oceń kompletność (jaki % aktywów ma sensory?), jakość (jaki % odczytów jest walidowalnych?), dostępność (ile systemów trzeba zintegrować?) i standaryzację (czy tagi są spójne między stacjami?). Standardy: ISO 14224 (zbieranie danych niezawodnościowych), IEC CDD (Common Data Dictionary). Firmy, które robią assessment PRZED zakupem platformy ML, oszczędzają

30–50% czasu wdrożenia.

F2. 58% kadry operacyjnej nie ufa AI — i ma do tego prawo

58% kadry operacyjnej nie ufa rekomendacjom AI (Eurelectric 2025). Gartner (Q4 2024) potwierdza: w organizacjach o wysokiej dojrzałości AI 57% jednostek biznesowych ufa; w niskiej dojrzałości — zaledwie 14%. To nie jest irracjonalny opór — to racjonalna odpowiedź na systemy, które generują fałszywe alarmy i nie potrafią wyjaśnić swoich decyzji.

Explainability — SHAP, LIME i ich ograniczenia. SHAP (SHapley Additive exPlanations) przypisuje ważoną kontrybucję każdej cechy do predykcji — ale jest kosztowny obliczeniowo: dla modelu z 500 cechami i 10 000 próbek, pełny SHAP zajmuje minuty. LIME buduje uproszczony model surrogatowy w otoczeniu konkretnej predykcji — szybszy, ale mniej wiarygodny globalnie. Najnowsze badania (MDPI 2025) sygnalizują spadek znaczenia post-hoc wyjaśnień na rzecz modeli z wbudowaną interpretowalnością: mechanizmy uwagi (attention maps) w Transformerach i dynamiczne systemy regułowe lepiej obsługują temporalne dane sensorowe.

Jak budować zaufanie — sprawdzone recepty:

Zaczynaj od pilotów na niekrytycznych aktywach — pozwól ekipie zobaczyć, że AI DZIAŁA, zanim powiesz im żeby mu ufali na transformatorze 100 MVA. Dokumentuj każdą zapobiegniętą awarię z wyliczeniem unikniętego kosztu — to buduje wiarygodność liczbami, nie obietnicami. Pokaż rozumowanie: dashboard powinien mówić nie tylko „alarm na łożysku #3” ale „kurtoza wzrosła z 3,1 do 5,8 w ciągu 14 dni, BPFO harmoniczne widoczne na 47 Hz, temperatura +4°C — wzorzec spójny z outer race defect stadium 1”. Ekspert widzi dane, nie czarną skrzynkę. Model **human-on-the-loop** (AI proponuje, człowiek zatwierdza) buduje zaufanie szybciej niż human-in-the-loop (człowiek interweniuje tylko gdy AI się myli) — bo daje operatorowi poczucie kontroli.

F3. EU AI Act od VIII 2026 — co to oznacza konkretnie dla PdM

AI w zarządzaniu infrastrukturą krytyczną = system **HIGH-RISK** (Annex III, Sekcja 2). Baker Botts (III 2026) ostrzega: „regulatorzy raczej nie będą interpretować ‘komponentu bezpieczeństwa’ wąsko, gdy egzekwowanie dotrze do energetyki.” Systemy PdM wyzwalające automatyczne akcje (auto-wyłączenie, derating) niemal pewnie kwalifikują się. Systemy czysto advisory-only są graniczne — ale konserwatywna klasyfikacja jest zalecana.

Konkretne wymogi od 2 sierpnia 2026:

- **Art. 9 — System zarządzania ryzykiem** w całym cyklu życia AI. Nie jednorazowa ocena, lecz ciągły proces: identyfikacja ryzyk, mitygacja, monitoring, aktualizacja. Dla PdM: co się stanie jeśli model FP wygeneruje fałszywy alarm i wyłączy transformator 200 MVA w szczycie?
- **Art. 10 — Jakość danych treningowych.** Kontrola biasu, kompletność, reprezentatywność. Dla PdM: jeśli model trenowany na danych z turbin Vestas jest wdrażany na Siemens Gamesa — czy dane są reprezentatywne? Kto to weryfikuje?
- **Art. 11 — Dokumentacja techniczna.** Pełen opis: cel systemu, architektura, dane treningowe, metryki, ograniczenia, instrukcja użytkowania. Vendor musi dostarczyć, operator musi utrzymywać.
- **Art. 12 — Logowanie.** System musi automatycznie rejestrować zdarzenia przez cały okres eksploatacji — każdą predykcję, każdy alert, każdą decyzję. Audit trail musi być dostępny dla regulatora.
- **Art. 14 — Nadzór ludzki.** Człowiek musi mieć możliwość monitorowania, interweniowania i nadpisania

decyzji AI. Dla prescriptive PdM z auto-WO: kto zatwierdza zlecenie — AI czy inżynier? Art. 14 sugeruje, że inżynier.

- **Art. 43, 71 — Ocena zgodności i rejestracja** w unijnej bazie danych.

Kary: do **€15 mln lub 3% globalnego obrotu** za naruszenie wymogów high-risk. Dla dużej utility z obrotem €5 mld: do €150 mln.

NIS2 — równoległy wymóg: polityki bezpieczeństwa IT/OT, obsługa incydentów (24h wstępna notyfikacja, 72h pełny raport), bezpieczeństwo łańcucha dostaw, szyfrowanie, MFA. Kary: do €10 mln lub 2% obrotu. System PdM podłączony do SCADA jest częścią infrastruktury OT — musi być objęty NIS2.

Co to oznacza praktycznie: każdy vendor PdM, który chce sprzedawać w UE po sierpniu 2026, musi albo wbudować compliance w platformę (logowanie, explainability, human oversight), albo wypaść z rynku europejskiego. Dla operatorów: budżet compliance (szacunki: €200K–€2M na dostosowanie istniejących systemów) trzeba zaplanować TERAZ, bo 5 miesięcy to za mało na budowę od zera.

F4. Kontekst polski — przedsiębiorca, nie salon

Polska energetyka stoi na progu cyfryzacji — ale jest to przedsiębiorca, nie salon. I warto to powiedzieć wprost, bo zbyt wiele polskich raportów branżowych maluje obraz różowiej niż jest.

Co się naprawdę dzieje:

Tauron — lider polskiej cyfryzacji energetycznej. Jako pierwsza spółka energetyczna w Polsce skorzystał z instrumentu KPO „Wspieranie zaawansowanej transformacji cyfrowej” — **310 mln zł** przeznaczonych na systemy monitoringu, analitykę predykcyjną oraz inteligentne liczniki. Strategia 2025–2035: ~100 mld zł inwestycji, w tym „predykcyjne zarządzanie majątkiem sieciowym” jako explicite nazwany cel. Do połowy 2025 zainstalowano 2 mln liczników zdalnego odczytu (33% klientów), cel: 100% do 2030. Plan rozwoju 2026–2031 zakłada podwojenie nakładów do 6 mld zł/rok. Modernizacja terenowa: drony, mobilne słupy, podnośniki PPN na podwoziu gąsienicowym.

PGE Dystrybucja — 47,5% klientów z LZO (przekroczony cel regulacyjny na 2025). 1,4 mld zł dotacji z KPO na modernizację sieci wiejskich. PGE Strategia 2035: bloki gazowe (Rybnik, Gryfino — ~6 mld zł z Siemens Energy), ale też cyfryzacja.

PSE — wymaga pre-approval dla AI wpływającego na dispatch. Po lekcji z blackoutu iberyjskiego (Hiszpania/Portugalia, IV 2025) regulator wzmocnił ostrożność — PSE wdrażają „pakiet antyblackoutowy” w Polsce. PSE planuje 5 tys. km nowych linii 400 kV i modernizację 100+ stacji do 2036 — ogromna szansa dla PdM na NOWYCH aktywach. TGE + PSE + Tauron Dystrybucja: porozumienie o platformie usług elastyczności (I 2026).

Polska przeznaczyła €3,2 mld z KPO na cyfryzację energetyki i zieloną transformację. URE i UODO rozwijają oczekiwania wobec AI. CSRD wymaga od polskich spółek energetycznych raportowania ESG od 2025–2026 — AI do monitoringu emisji staje się compliance requirement, nie opcją.

Uczciwa ocena dojrzałości:

Wymiar	Faza	Komentarz
Inteligentne liczniki (AMI)	1–2	33–47% penetracja, cel 100% do 2030
Monitoring stanu aktywów (CbM)	0–1	Pilotaże, Tauron 310 mln zł, ale brak wdrożeń produkcyjnych ML

Predykcyjne utrzymanie (PdM AI)	0	Zero publicznych case studies PdM z ML w polskiej energetyce
Prescriptive / Autonomous	0	Poza horyzontem — najpierw CbM i dane

Co to oznacza praktycznie: polskie utility są na Fazie 0–1 adopcji AI w PdM. €3,2 mld z KPO daje szansę na skok — ale **310 mln zł Taurona na analitykę predykcyjną to pierwszy publiczny sygnał**, że ktoś w Polsce traktuje PdM poważnie. Firmy, które dzisiaj zainwestują w data readiness (standaryzacja tagów SCADA, integracja OT/IT, historian AVEVA PI), będą gotowe na AI za 2–3 lata. Reszta będzie kupować gotowe rozwiązania od vendorów zachodnich — i płacić premium za brak przygotowania.

Key insight: Polska energetyka jest na Fazie 0 adopcji PdM AI — brak publicznych wdrożeń ML na aktywach sieciowych. Ale Tauron z 310 mln zł z KPO i explicite nazwanym „predykcyjnym zarządzaniem majątkiem” to pierwszy sygnał, że coś się rusza. Okno możliwości: 2026–2028 to czas na fundament danych. Kto go położy, wygra.

Wnioski — co się zmienia najszybciej i co z tego wynika

Po przeczytaniu setek stron raportów, papierów i case studies, trzy rzeczy mnie zaskoczyły:

1. Foundation models zmieniają reguły gry. Chronos-2, Granite, Lag-Llama umożliwiają zero-shot forecasting na danych IoT — bez kosztownego trenowania per aktywo. To demokratyzacja: mniejsze utility, które nie stać na zespoły data science, mogą wskoczyć na poziom predykcyjny z modelem pre-trained na milionach serii czasowych. Ten trend za 2–3 lata zmieni strukturę rynku.

2. Prescriptive jest gotowe technicznie, ale organizacyjnie wciąż w powijkach. Workflow z 8 kroków (detekcja → diagnoza → RUL → magazyn → harmonogram → auto-WO → derating → feedback) jest możliwy do zbudowania dziś — ale wymaga integracji 5–7 systemów (CMS + SCADA + CMMS + ERP + forecasting + scheduling + kontroler turbiny). Mniej niż 10% utility jest na tym poziomie. Tu jest największa luka między technologią a organizacją.

3. Fosa danych OEM-ów się pogłębia. GE Vernova z 57 000 turbin, Hitachi Energy z proprietary grid data, Siemens z born-connected Sensformerami — ich przewaga w transfer learning i pre-trained models rośnie z każdym rokiem eksploatacji tysięcy aktywów. Pure-software vendorzy muszą budować modele od zera u każdego klienta.

Jedna rzecz mnie rozczarowała: **brak otwartych benchmarków**. Każdy vendor podaje swoje metryki na swoich danych. Nie ma odpowiednika ImageNet czy GLUE dla predykcyjnego utrzymania w energetyce. Zbiór CARE (3 farmy wiatrowe, 2024) to krok w dobrą stronę — ale to wciąż za mało. Bez standardowych benchmarków, porównanie vendorów pozostaje ćwiczeniem w zaufaniu do marketingu.

Strategiczna implikacja: inwestycja w **data-ready organization** (standaryzacja tagów ISO 14224, konwergencja OT/IT, data governance) przyniesie wyższy ROI niż kolejny upgrade platformy ML. Dane to fundament. Bez niego nawet najlepszy algorytm jest ślepy.