

**Politechnika
Warszawska**

**Adaptacyjne sterowanie
częstotliwością pomiarów
dla brzegowego uczenia maszynowego**

Piotr Posiadała

Promotor: dr hab. inż. Krzysztof Perlicki, prof. PW

Opiekun naukowy: mgr inż. Marcin Golański



2

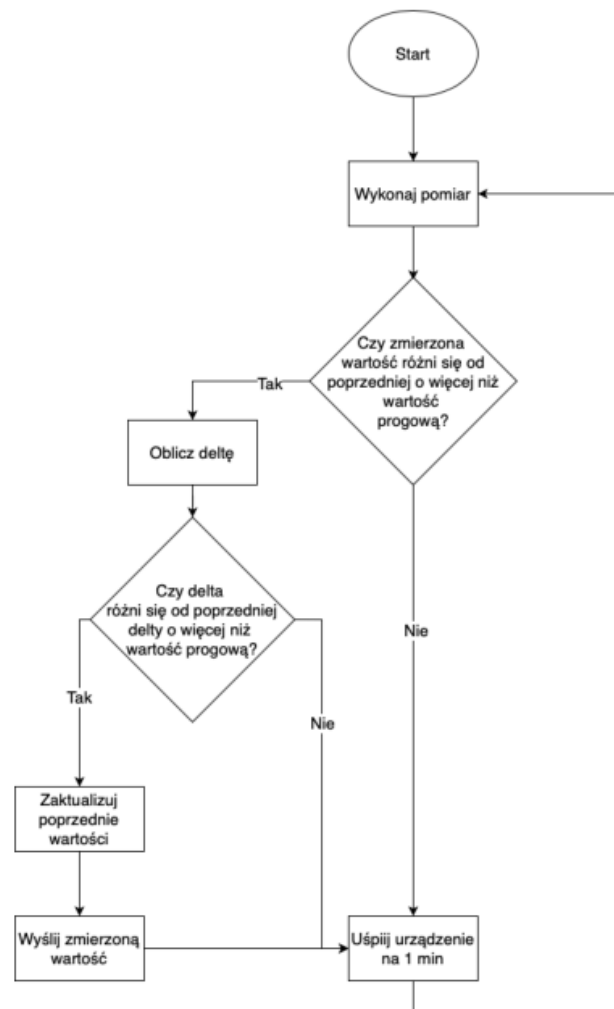
Motywacja // Źródło

Politechnika
Warszawska



Rozwiązania podobne

G. Zdunek, „Metody adaptacyjnej zmiany częstotliwości pomiarów w sieciach LoRaWAN”, prac.mag., Wydział Elektroniki i Technik Informatycznych, Politechnika Warszawska, 2020.



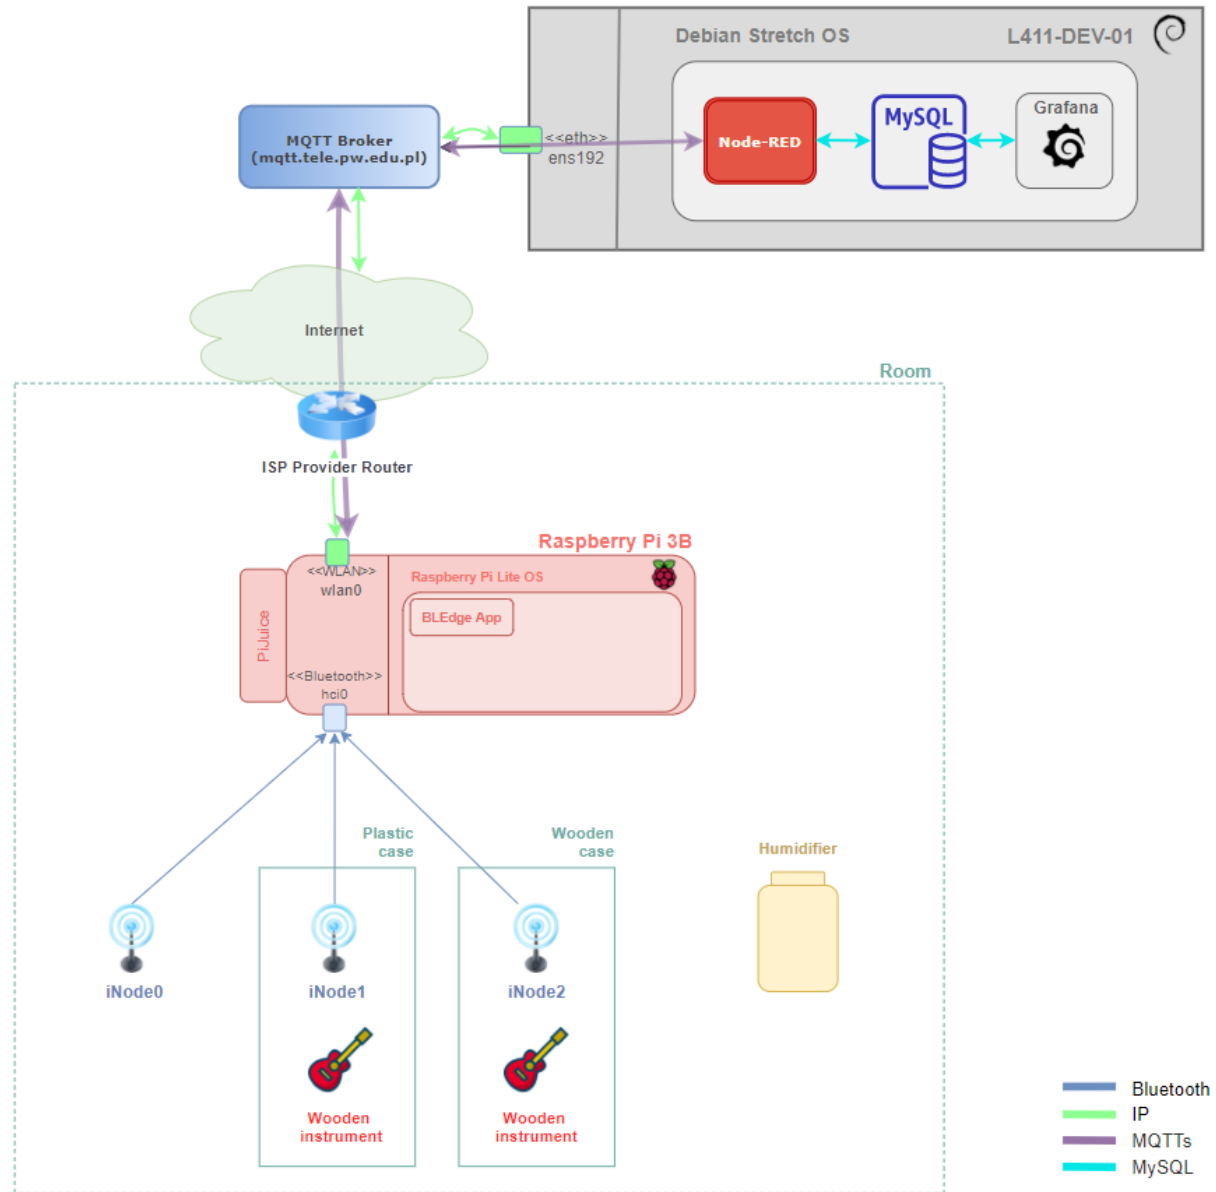
Teza badawcza

4

Dzięki wprowadzeniu algorytmu działającego na brzegu sieci, pozwalającego na adaptacyjne dostosowywanie częstotliwości pomiarów, możliwe jest zmniejszenie liczby przesyłanych w sieci pakietów przy akceptowalnym spadku dokładności realizowanych pomiarów

Dzięki dodaniu logiki możliwe jest ograniczenie zużycia energii ze szczególnym uwzględnieniem urządzenia działającego na brzegu sieci

Architektura rozwiązania



Wybrane algorytmy z biblioteki SciKit-Learn:

- LinearRegression
- Lasso
- Ridge
- ElasticNet
- SVR
- RandomForest

Ocena efektywności działania algorytmu

- **Błąd MAPE (średni bezwgl. błąd procentowy):**
 - Podział na dane uczące i testowe
 - Algorytm nie wie o wartości wilgotności od pewnego momentu w czasie
 - Porównanie wartości wilgotności zmierzonej z wartościami przewidywanymi
- **Wewnętrzna metoda SciKit-Learn → score()**
 - W praktyce: współczynnik determinacji R2

	year	month	day	hour	minute	weekday	node	humidity
0	2021	9	8	17	5	2	0	60.80
1	2021	9	8	17	5	2	1	58.22
2	2021	9	8	17	5	2	2	56.10
3	2021	9	8	17	10	2	0	60.48
4	2021	9	8	17	10	2	1	58.16
...
14835	2021	11	6	23	45	5	1	55.73
14836	2021	11	6	23	45	5	2	52.57
14837	2021	11	7	0	0	6	0	47.54
14838	2021	11	7	0	0	6	1	55.72
14839	2021	11	7	0	0	6	2	52.55

Przewidywanie

	year	month	day	hour	minute	weekday	node	humidity
0	2021	11	7	0	15	6	0	56.128419
1	2021	11	7	0	15	6	1	54.144201
2	2021	11	7	0	15	6	2	52.159983
3	2021	11	7	0	30	6	0	56.126191
4	2021	11	7	0	30	6	1	54.141972
...
187	2021	11	7	16	45	6	1	53.980506
188	2021	11	7	16	45	6	2	51.996288
189	2021	11	7	17	0	6	0	55.961458
190	2021	11	7	17	0	6	1	53.977239
191	2021	11	7	17	0	6	2	51.993021


	year	month	day	hour	minute	weekday	node	humidity
0	2021	11	7	0	15	6	0	47.94
1	2021	11	7	0	15	6	1	55.69
2	2021	11	7	0	15	6	2	52.52
3	2021	11	7	0	30	6	0	47.60
4	2021	11	7	0	30	6	1	55.66
...
187	2021	11	7	16	45	6	1	55.53
188	2021	11	7	16	45	6	2	52.62
189	2021	11	7	17	0	6	0	64.20
190	2021	11	7	17	0	6	1	55.84
191	2021	11	7	17	0	6	2	52.65

MAPE

Dane wejściowe

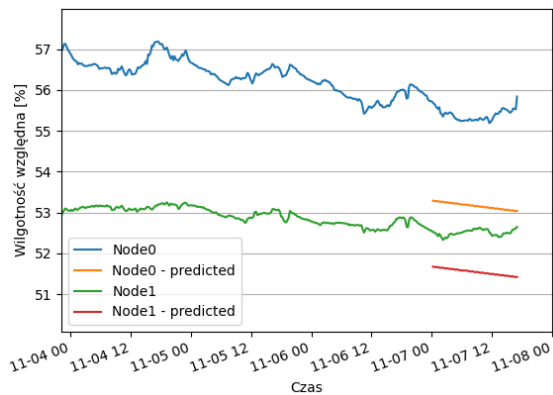
- Pomiar wykonywane w interwale 15-minutowym
- Zbieranie danych przez 2 miesiące
- Ok. 15 tys. rekordów dla łącznie 3 węzłów pomiarowych
- Dane uczące w postaci:

	year	month	day	hour	minute	weekday	node	humidity
0	2021	9	8	17	5	2	0	60.80
1	2021	9	8	17	5	2	1	58.22
2	2021	9	8	17	5	2	2	56.10
3	2021	9	8	17	10	2	0	60.48
4	2021	9	8	17	10	2	1	58.16
...
14835	2021	11	6	23	45	5	1	55.73
14836	2021	11	6	23	45	5	2	52.57
14837	2021	11	7	0	0	6	0	47.54
14838	2021	11	7	0	0	6	1	55.72
14839	2021	11	7	0	0	6	2	52.55




Wyniki badań


Linear Regression:



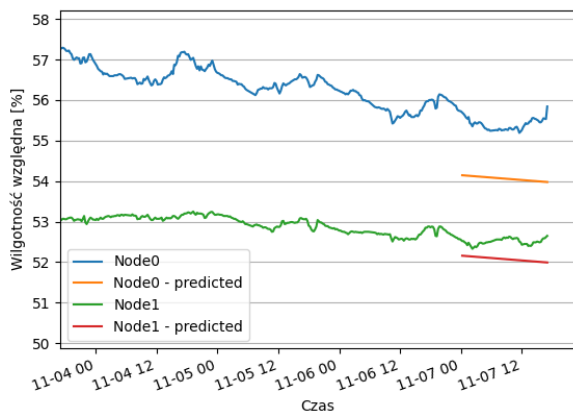
Ridge:



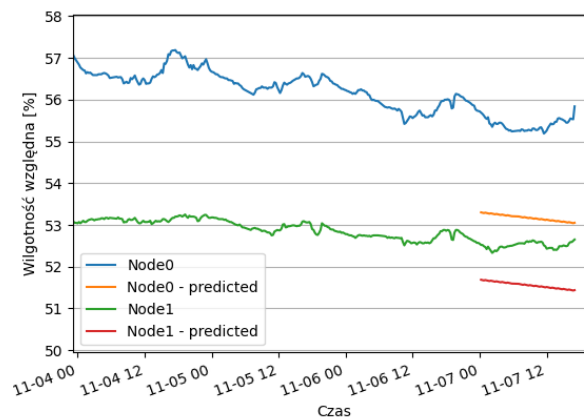
Lasso:




SVR:



ElasticNet:




RandomForest:



Wyniki badań

Algorithm	Node	Score (sci-kit learn build-in method)	MAPE (for first N predictions)			
			4	16	64	256
Linear Regression	Node1	0,3032	4,23%	4,02%	3,91%	4,04%
	Node2		1,59%	1,51%	1,76%	1,83%
Lasso	Node1	0,0764	1,80%	2,06%	2,31%	2,23%
	Node2		7,66%	7,79%	7,65%	7,65%
Ridge	Node1	0,3032	4,23%	4,02%	3,91%	4,04%
	Node2		1,59%	1,51%	1,76%	1,83%
Elastic Net	Node1	0,3031	4,21%	4,01%	3,90%	4,03%
	Node2		1,56%	1,49%	1,74%	1,81%
SVR	Node1	0,2910	2,69%	2,46%	2,31%	2,42%
	Node2		0,65%	0,56%	0,77%	0,82%
Random Forest	Node1	0,9970	0,08%	0,32%	0,39%	0,34%
	Node2		0,23%	0,35%	0,20%	0,22%

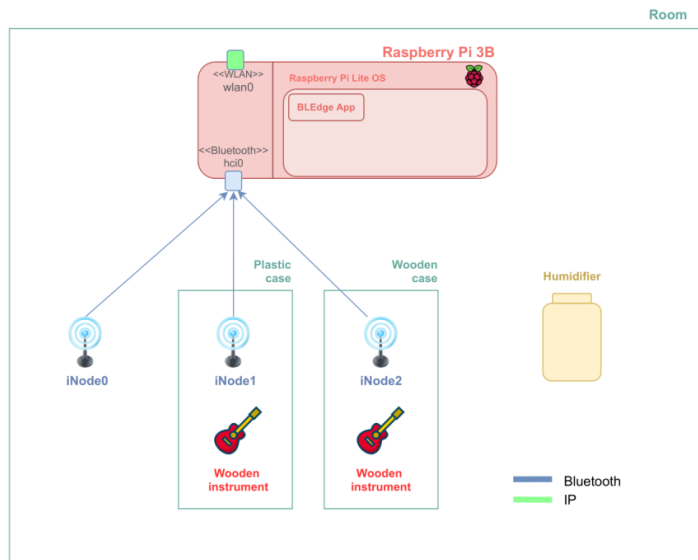
Predykcja zmian wilgotności



Testy implementacji

Uruchomienie aplikacji na RPI w 3 wersjach:

- Stały interwał – pomiar odniesienia
- Analiza różnicy/delty
- Predykcja



Wyniki

Czas życia na baterii i ilość uruchomień urządzenia brzegowego

- Wydłużenie czasu życia na baterii o 7,8%
- 30-krotnie mniejsza liczba uruchomień węzła
- Przyczyna: brak odcięcia dopływu prądu do RPI z baterii

Algorithm	Battery lifetime [min]	Number of measurements made by edge device per sensor
Delta	3090	206
Random Forest Prediction	3330	7

Wyniki

Błąd MAPE

- 2-krotny wzrost błędu MAPE dla opracowanej implementacji względem trybu delty
- Spadek dokładności wraz z czasem uruchomienia aplikacji
- Spadek dokładności to koszt

Algorithm	Node	MAPE (for first N days)		
		N = 4	N = 8	N = 12
Constant Interval	Node1	0,00%	0,00%	0,00%
	Node2	0,00%	0,00%	0,00%
Delta	Node1	0,19%	0,20%	0,21%
	Node2	0,17%	0,15%	0,17%
Random Forest Prediction	Node1	0,30%	0,33%	0,46%
	Node2	0,15%	0,20%	0,27%
Random Forest Prediction (simulation)	Node1	0,32%	0,48%	0,56%
	Node2	0,28%	0,31%	0,36%

Wyniki

Ilość pomiarów odebranych na brokerze vs wykonanych na urządzeniu brzegowym

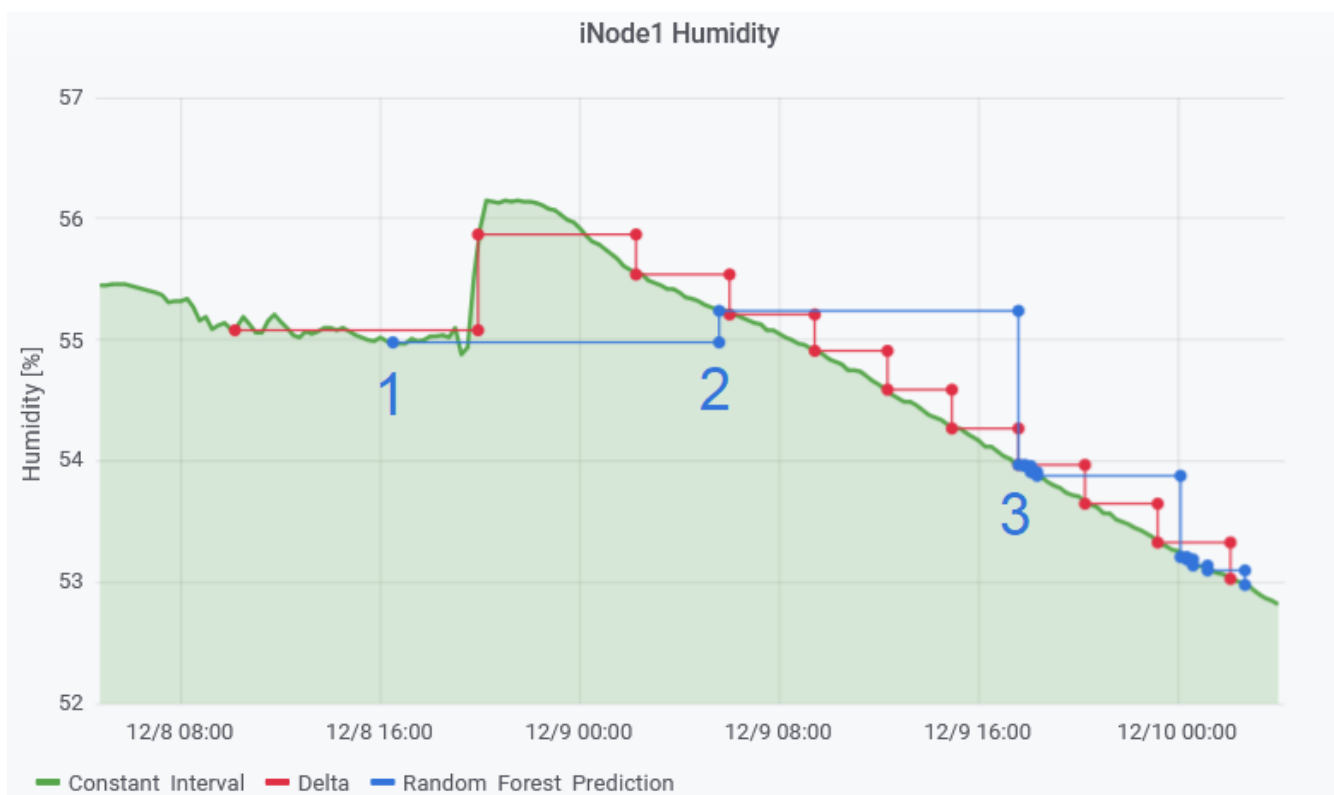
- W wersji podstawowej:
 - 60% więcej przesłanych pomiarów względem trybu delty
- W wersji rozszerzonej:
 - 50% mniej przesłanych pomiarów względem trybu delty
 - Efekt – wzrost błędu MAPE
- 12-krotny spadek uruchomień węzła (korzyść)

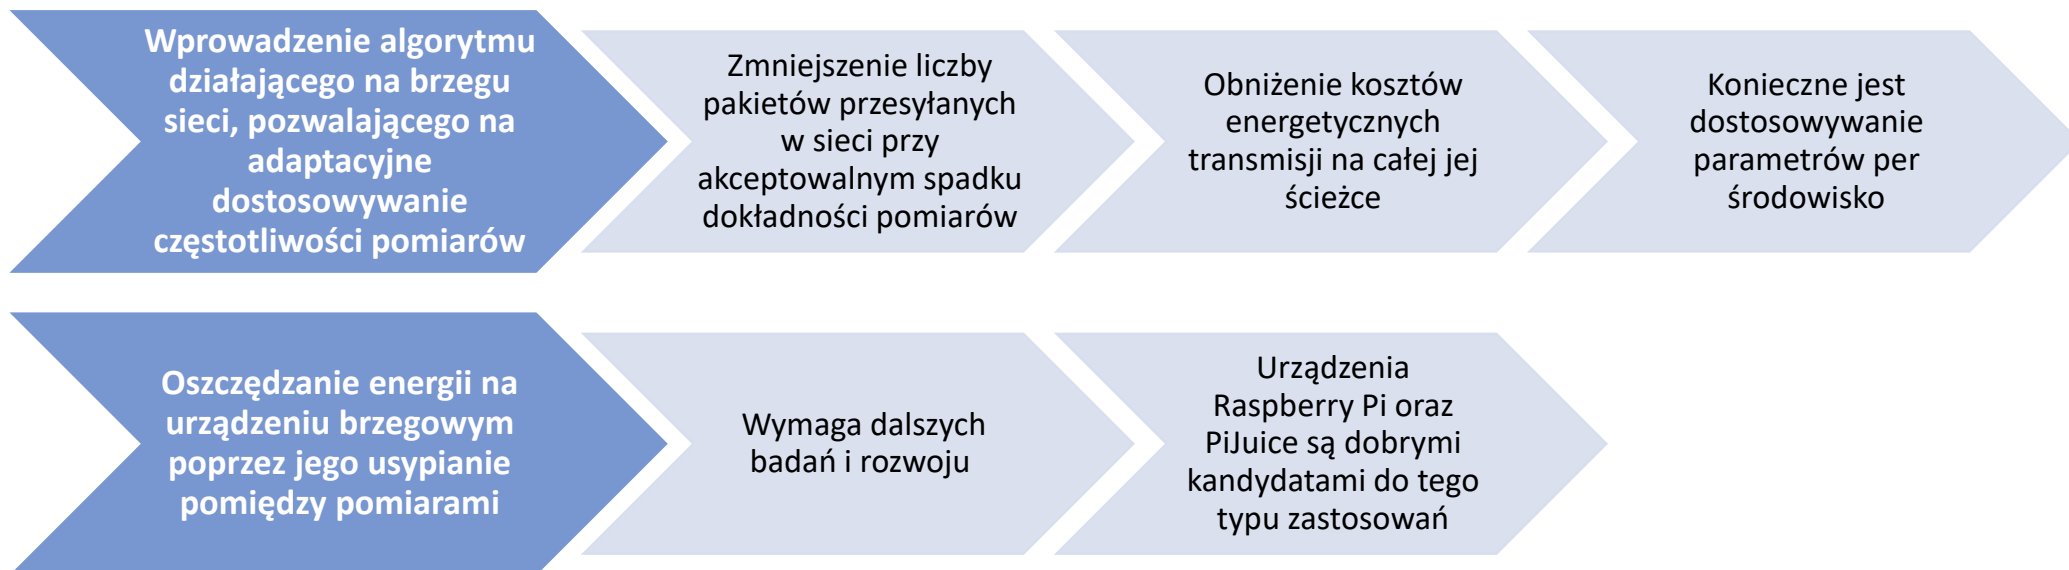
Algorithm	Node	Number of measurements received at broker (for first N days)		
		N = 4	N = 8	N = 12
Constant Interval	Node1	364	729	1096
	Node2	364	729	1096
Delta	Node1	13	37	62
	Node2	13	37	62
Random Forest Prediction	Node1	35	70	100
	Node2	35	70	100
Random Forest Prediction (simulation)	Node1	6	17	32
	Node2	6	17	32

Algorithm	Node	Number of measurements made by edge device (for first N days)		
		N = 4	N = 8	N = 12
Constant Interval	Node1	384	786	1152
	Node2	384	786	1152
Delta	Node1	384	786	1152
	Node2	384	786	1152
Random Forest Prediction	Node1	35	70	100
	Node2	35	70	100
Random Forest Prediction (simulation)	Node1	35	70	100
	Node2	35	70	100

Wyniki

Reakcja na anomalie





Podsumowanie

- Analiza problemu, literatury, dostępnych technik, prototypowanie
- Zaplanowanie architektury rozwiązania
- Konfiguracja i development środowiska badawczego
 - Konfiguracja węzłów końcowych (iNode) oraz brzegowych (RPI, PiJuice)
 - Aplikacja w języku Python (BLEdge), skrypty powłoki Bash
 - Przetwarzanie i analiza ramek Bluetooth
 - Zapisywanie pomiarów w lokalnej bazie danych
 - Ustalanie kolejnego pomiaru (Delta/Predykcja/Stały interwał)
 - Połączenie MQTT
 - Uspianie urządzenia
 - Konfiguracja serwisów maszyny wirtualnej (MySQL, Mosquitto, Node-RED, Grafana)
 - Zabezpieczenie połączenia (TLS)
- Zebranie danych pomiarowych
- Badanie efektywności nieskomplikowanych algorytmów ML dla zestawionego środowiska
- Implementacja logiki bazującej na wybranym algorytmie
- Porównanie opracowanej logiki z rozwiązaniem podobnym oraz pomiarem referencyjnym
- Analiza wyników

**Politechnika
Warszawska**

**Adaptacyjne sterowanie
częstotliwością pomiarów
dla brzegowego uczenia maszynowego**

Piotr Posiadała

Promotor: dr hab. inż. Krzysztof Perlicki, prof. PW

Opiekun naukowy: mgr inż. Marcin Golański

