



UNIwersytet  
Warszawski




ŚLCJ

# Algorytm genetyczny dla fizyków: przykład zastosowania w analizie wzbudzeń kulombowskich

*Paweł J. Napiorkowski*


# Program

- Motywacja.  
*Czego szukamy*
- Algorytm genetyczny.  
*Jak to działa*
- Implementacja.  
*Co zrobiliśmy*
- Rozszerzenia.  
*Co uzyskaliśmy dodatkowo*


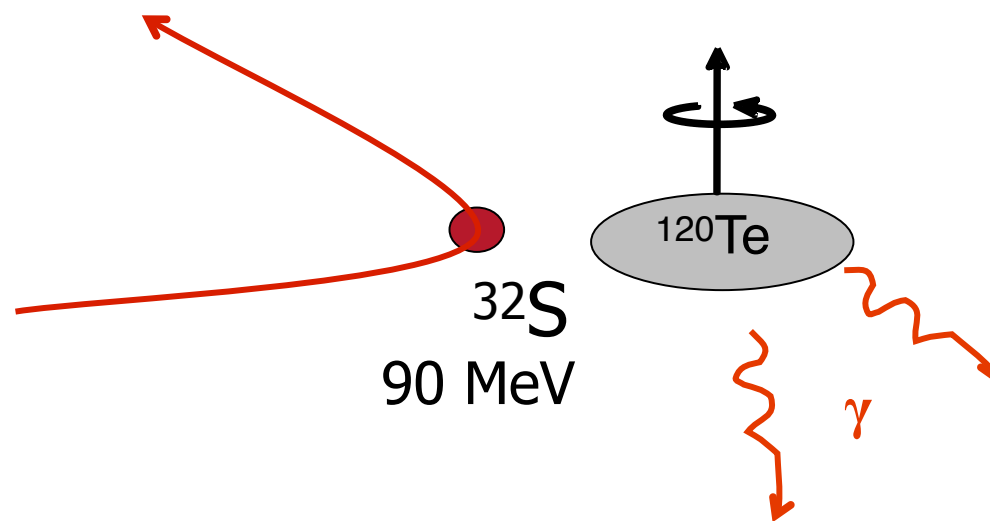


A. Basak and J. D. Lohn, 2013 IEEE Congress on Evolutionary Computation, Cancun, 2013, pp. 598-604, doi: 10.1109/CEC.2013.6557623.

# Definicja problemu: wzbudzenia kulombowskie



**Detektor cząstek.**  
np. zastaw PiN-diod  
detektory Si 5×5 mm  
θ: 110÷176 deg




**EAGLE**  
do 30 HPGe z ACS


$$E_{\max}(MeV) = 1.44 \frac{A_1 + A_2}{A_2} \cdot \frac{Z_1 Z_2}{1.25(A_1^{1/3} + A_2^{1/3}) + 5}$$



# Definicja problemu: wzbudzenia kulombowskie



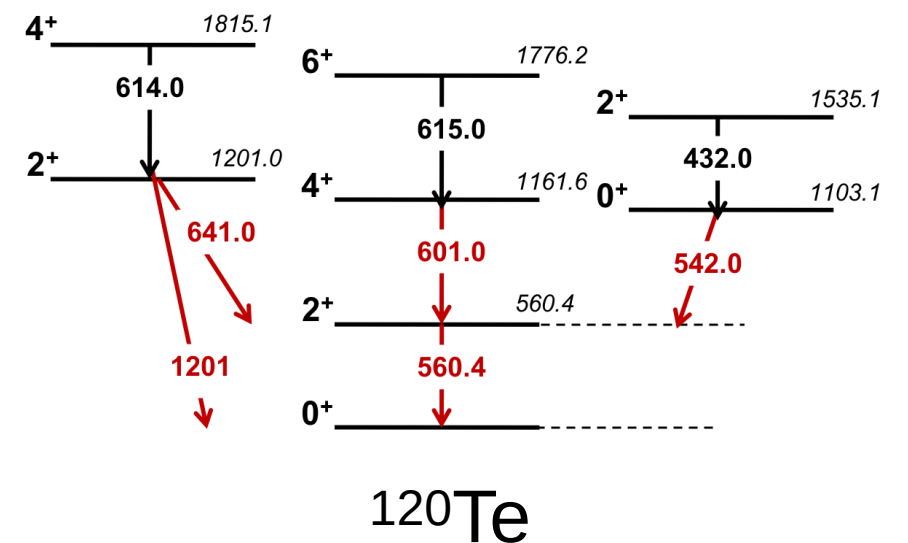

**Detektor cząstek.**  
np. zastaw PiN-diod  
detektory Si 5×5 mm  
 $\theta$ : 110÷176 deg



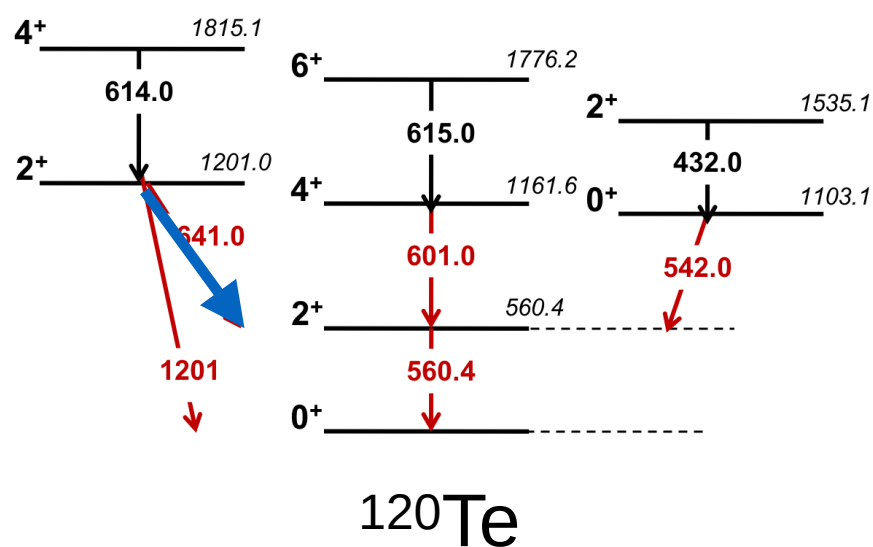
A semiclassical coupled-channel  
Coulomb excitation least-squares search code,

T. Czosnyka, D. Cline, C.Y. Wu  
Am. Phys. Soc. 28:745 (1983)


[www.http://slcj.uw.edu.pl/gosia/](http://slcj.uw.edu.pl/gosia/)



# Definicja problemu minimalizacja $\chi^2$




$\chi^2$




$\langle 2_1^+ || E2 || 2_2^+ \rangle$  [eb]

# Minimalizacja $\chi^2$ metoda gradientowa




$\chi^2$




metoda najszybszego spadku

$\langle 2_1^+ || E2 || 2_2^+ \rangle$  [eb]

# Minimalizacja $\chi^2$ metoda gradientowa




$\chi^2$




metoda najszybszego spadku

$\langle 2_1^+ \| E_2 \| 2_2^+ \rangle$  [eb]

# Minimalizacja $\chi^2$ metoda gradientowa



$\chi^2$

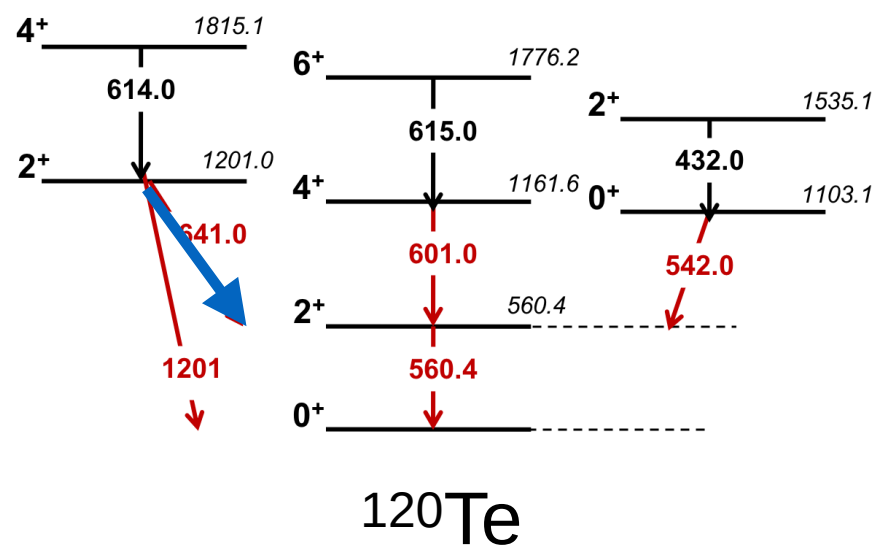


$\langle 2_1^+ || E2 || 2_2^+ \rangle$  [eb]


Podstawowy problem:  
metoda gradientowa jest wrażliwa  
na minima lokalne



# Minimalizacja $\chi^2$ metoda gradientowa



$\chi^2$




Podstawowy problem:  
metoda gradientowa jest wrażliwa  
na minima lokalne

**Rozwiązanie: random restart**


$\langle 2_1^+ || E2 || 2_2^+ \rangle [eb]$

# Minimalizacja $\chi^2$ metoda gradientowa

31D



$\chi^2$



Podstawowy problem:  
metoda gradientowa jest wrażliwa  
na minima lokalne

Rozwiązanie: random restart

Jednak mało efektywne w przypadkach wielowymiarowych


$$\langle 2_1^+ || E2 || 2_2^+ \rangle [\text{eb}]$$

# Minimalizacja $\chi^2$

## symulowane wyżarzanie

1. wyznacz  $x_0$  i  $T$
2. wybierz  $x$  (wylosuj lub wylicz)
3. wylicz  $\Delta\chi^2 = \chi^2(x) - \chi^2(x_0)$
4. jeśli  $\Delta\chi^2 < 0 \rightarrow$  idź do 2.  
jeśli  $\Delta\chi^2 > 0$  wylicz  $p = \exp(-\Delta\chi^2/T)$  i  
porównaj z liczbą losową  $(0,1)$
5. jeśli  $p < r \rightarrow$  idź do 2.  
jeśli  $p > r$  zaakceptuj nowe  $x$ , zredukuj  $T$   
 $\rightarrow$  idź do 2.

$\chi^2$

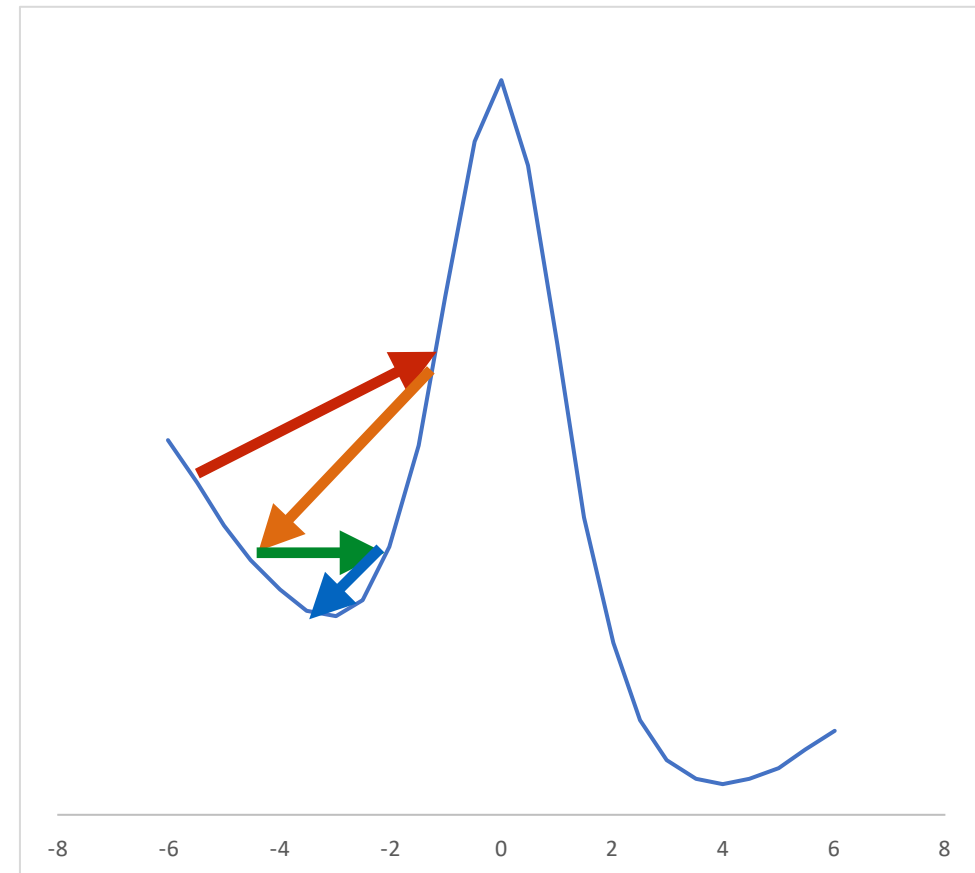


$\langle 2_1^+ || E_2 || 2_2^+ \rangle$  [eb]

# Minimalizacja $\chi^2$ symulowane wyżarzanie

1. wyznacz  $x_0$  i  $T$
2. wybierz  $x$  (np. wylosuj lub wylicz)
3. wylicz  $\Delta\chi^2 = \chi^2(x) - \chi^2(x_0)$
4. jeśli  $\Delta\chi^2 < 0 \rightarrow$  idź do 2.  
jeśli  $\Delta\chi^2 > 0$  wylicz  $p = \exp(-\Delta\chi^2/T)$   
i porównaj z liczbą losową  $(0,1)$
5. jeśli  $p < r \rightarrow$  idź do 2.  
jeśli  $p > r$  zaakceptuj nowe  $x$ , zredukuj  $T$   
 $\rightarrow$  idź do 2.

$\chi^2$



SA zaimplementowane w programie GOSIA w 1994 r.  
nie w pełni spełniło oczekiwania


# Minimalizacja $\chi^2$ algorytm genetyczny

- definiujemy  $x=a+(l/2^n)*(b-a)$   
 $l$  - liczba całkowita o  $n$ -bitach  

0	1	1	0	1	1	0	0
---	---	---	---	---	---	---	---

 $\equiv -0.9375$
- losujemy pewną liczbę punktów  $x_i$
- obliczamy wartości  $\chi^2(x_i)$
- zostawiamy część liczb o najmniejszym  $\chi^2$   
pozostałe wymieniamy na nowe

$\chi^2$



$\langle 2_1^+ || E_2 || 2_2^+ \rangle$  [eb]



# Minimalizacja $\chi^2$

## algorytm genetyczny

- definiujemy  $x = a + (l/2^n) * (b - a)$   
 $l$  - liczba całkowita o  $n$ -bitach

$$\boxed{01101100} \equiv -0.9375$$

- losujemy pewną liczbę punktów  $x_i$

- obliczamy wartości  $\chi^2(x_i)$

- zostawiamy część liczb o najmniejszym  $\chi^2$   
 pozostałe zastępujemy nowymi

- krzyżowanie:

$$\begin{array}{|c|c|c|c|c|c|c|c|} \hline 0 & 1 & 1 & 0 & 1 & 1 & 0 & 0 \\ \hline \end{array} \quad \begin{array}{|c|c|c|c|c|c|c|c|} \hline 1 & 0 & 0 & 1 & 1 & 0 & 0 & 1 \\ \hline \end{array}$$

-0.9375 1.171875

- mutacja: -1.078125

$$\begin{array}{|c|c|c|c|c|c|c|c|} \hline 0 & 1 & 0 & 0 & 1 & 0 & 0 & 1 \\ \hline \end{array}$$

-2.578125

- obliczamy wartości  $\chi^2(x_i)$  dla nowych  $x_i$

- powtarzamy od 4.

Jest to kanoniczna postać algorytmu genetycznego Johna Hollanda

# Minimalizacja $\chi^2$

## Podsumowanie

### 1. Gradient

+ znajduje szybko i dokładnie minimum lokalne

- wymaga wielu testów, aby znaleźć prawdopodobne minimum globalne

### 2. Symulowane wyżarzanie

+ może znaleźć minimum globalne

- nie radzi sobie z wysokimi barierami między minimami

### 3. Algorytm genetyczny

+ przeszukuje całą przestrzeń lepiej niż algorytm Monte-Carlo

+/- znajduje prawdopodobne minimum globalne (ale niedokładnie)

+/- kosztowny obliczeniowo, ale łatwy do zrównoleglenia

- brak dobrych kryteriów stopu i doboru parametrów algorytmu

# Zastosowanie algorytmów genetycznych

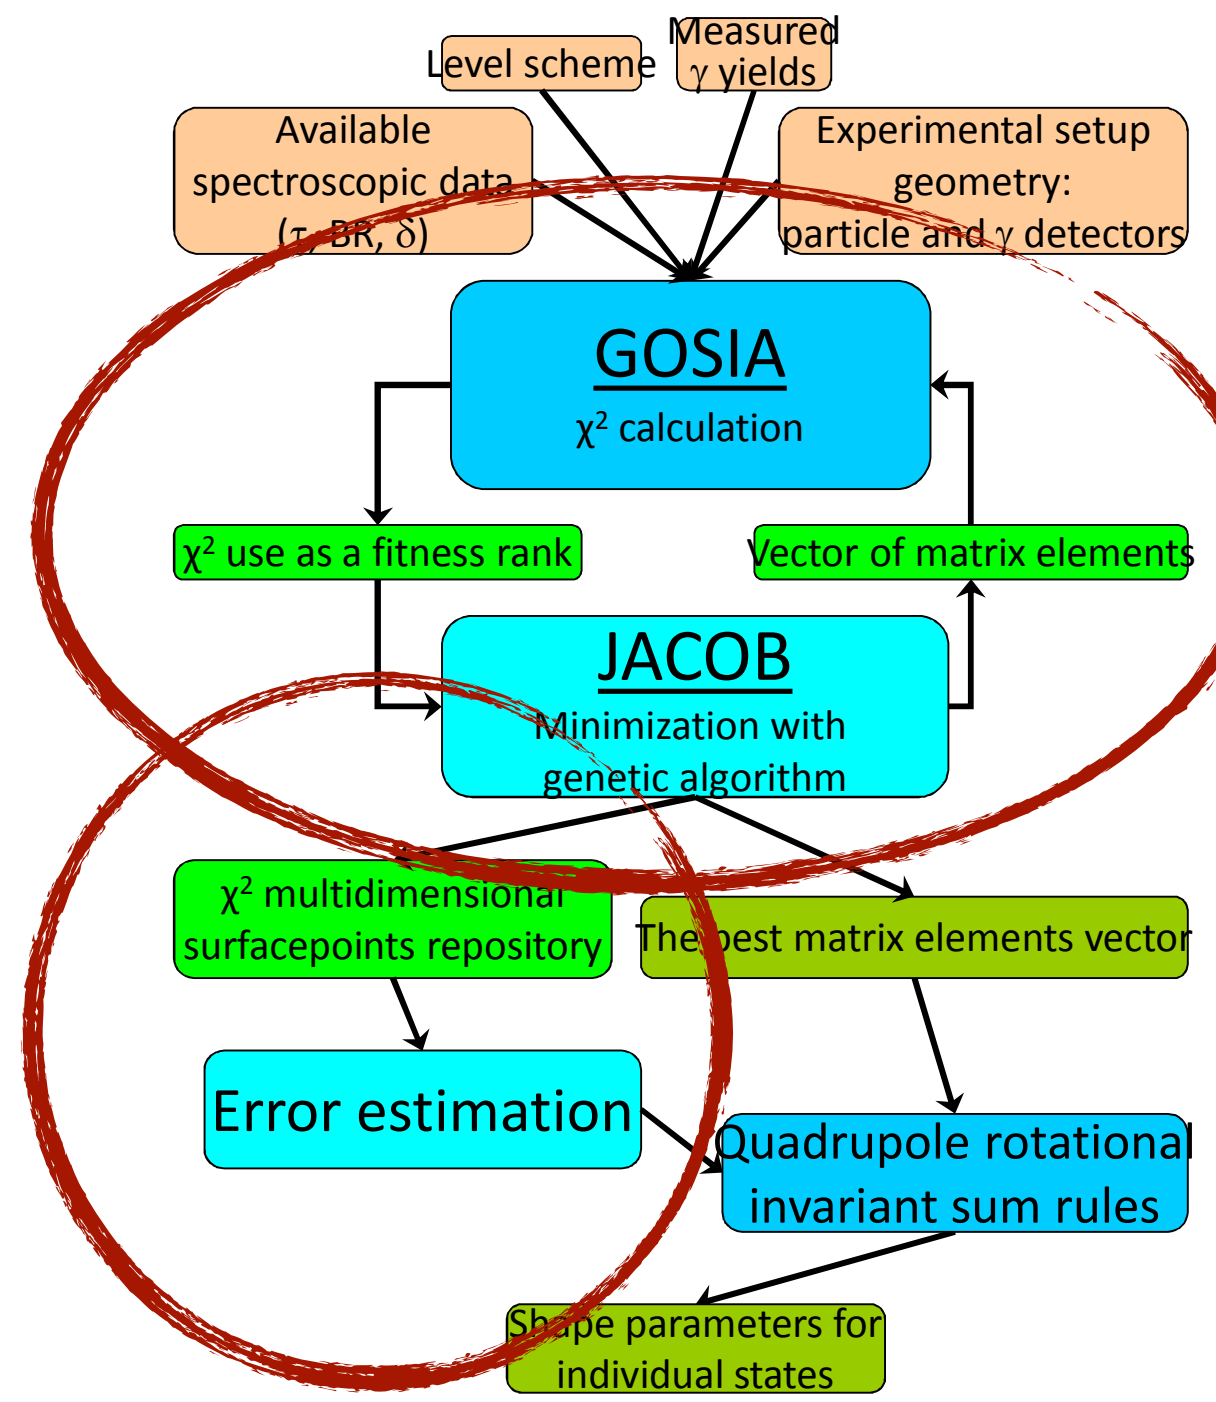
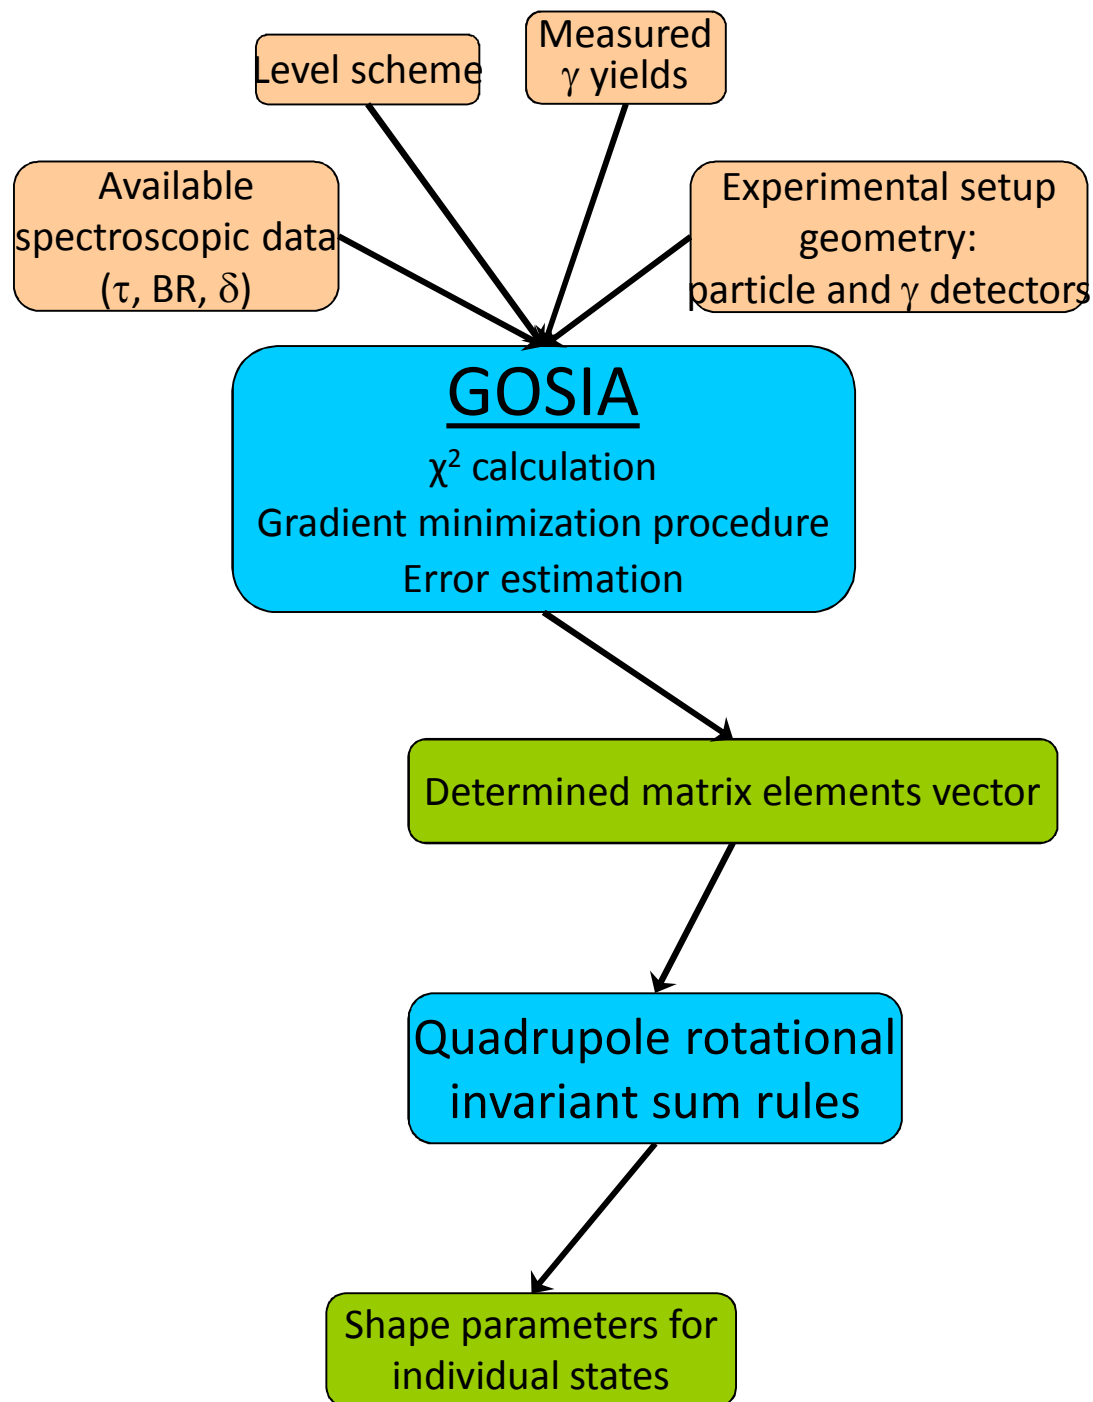
- **Optymalizacja wieloparametryczna**
  - Projektowanie obwodów elektronicznych
  - Szkolenie sieci neuronowych
- **Analiza eksperymentów wzbudzeń kulombowskich.**



A. Basak and J. D. Lohn, 2013 IEEE Congress on Evolutionary Computation, Cancun, 2013, pp. 598-604, doi: 10.1109/CEC.2013.6557623.

# JACOB:

## algorytm genetyczny dla GOSIA



# Jacob

```
Generation: 193
Best ChiSq: 0.711367
ME[0]: 1.01525
ME[1]: 0.316926
ME[2]: 1.65967
ME[3]: 1.05255
Average ChiSq: 43.5546
SYMULATION MENU:
4 - Stop symulation
5 - Show time measurement

Time Of Generation: 0.06 s
Time Of Gosia Call: 0.00142857 s
Number Of Gosia Calls: 35
Time Of Selection: 0 s
Time Of Crossing Over: 0 s
Time Of Mutation: 0 s
Number Of Generations: 193
█
```



# JACOB

The screenshot displays the JACOB v2.1 software interface within an xterm window. The interface is divided into several sections:

- Terminal (Left):** Shows simulation progress: Generation: 193, Best ChiSq: 0,71, ME[0]: 1,01525, ME[1]: 0,316926, ME[2]: 1,65967, ME[3]: 1,05255, Average ChiSq: 4. A simulation menu is visible with options: 4 - Stop simulat, 5 - Show time me. Below this, time measurements are listed: Time Of Generati, Time Of Gosia Ca, Number Of Gosia, Time Of Selectio, Time Of Crossing, Time Of Mutation, Number Of Genera.
- Simulation (Top Left):** Population size: 150, Average chiSq: 1828306, Best chiSq: 9,811, Best ME vector: 0,206, 0,064, -0,150, 0,447, 0,221, -0,247, 0,543, -1,162, 0,093, -1,126. Options: One generation (unselected), Number of generations: 875 (selected).
- Algorithm settings (Top Right):** Selection: truncation, Casualties [%]: 60, Crossing over: Parent by roulette, Max children: 5, Mutation: constant, Probability: 0,10, Sigma: 0,20.
- Time measurement (Bottom Left):** Time of generation: 19,250 s, Time of Gosia call: 0,204 s, Number of Gosia calls: 94, Time of selection: 0,000 s, Time of crossing over: 0,000 s, Time of mutation: 0,000 s, Time of others: 0,031 s.
- Logs and Repository (Bottom Right):** Save repository button, Log file checked, Log file path: C:\Users\Pawelek\Desktop\Jacob\_pjn\log.txt, Store best creature from each generation checked, Best creature path: C:\Users\Pawelek\Desktop\Jacob\_pjn\best.txt.
- Status Bar (Bottom):** Generation number: 1225, Remaining time: 4 h 30 min, Memory usage: 181468 K.

# Skuteczność algorytmu

Test z wykorzystaniem 6D funkcji testowej F7 - funkcji Schaffera

Przeprowadzono of 1 000 procesów minimalizacyjnych

$$F7(x_{1,\dots,6}) = \sum_{i=1}^6 a_i x_i \sin(\sqrt{|a_i x_i|})$$


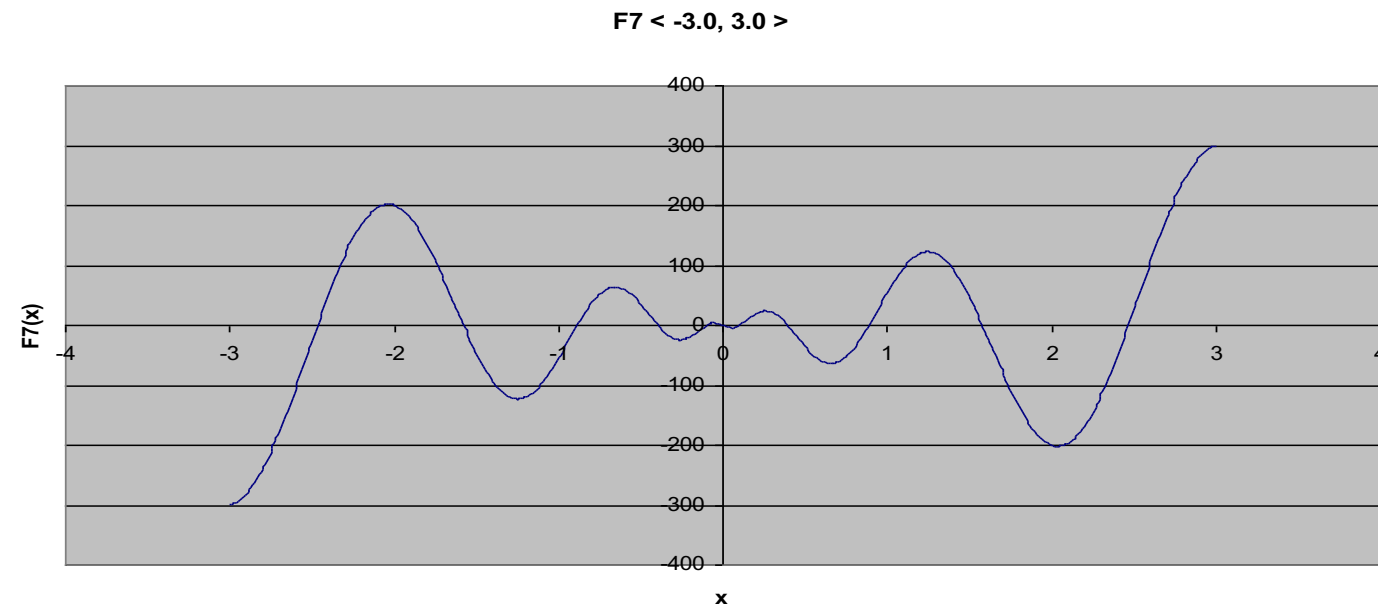
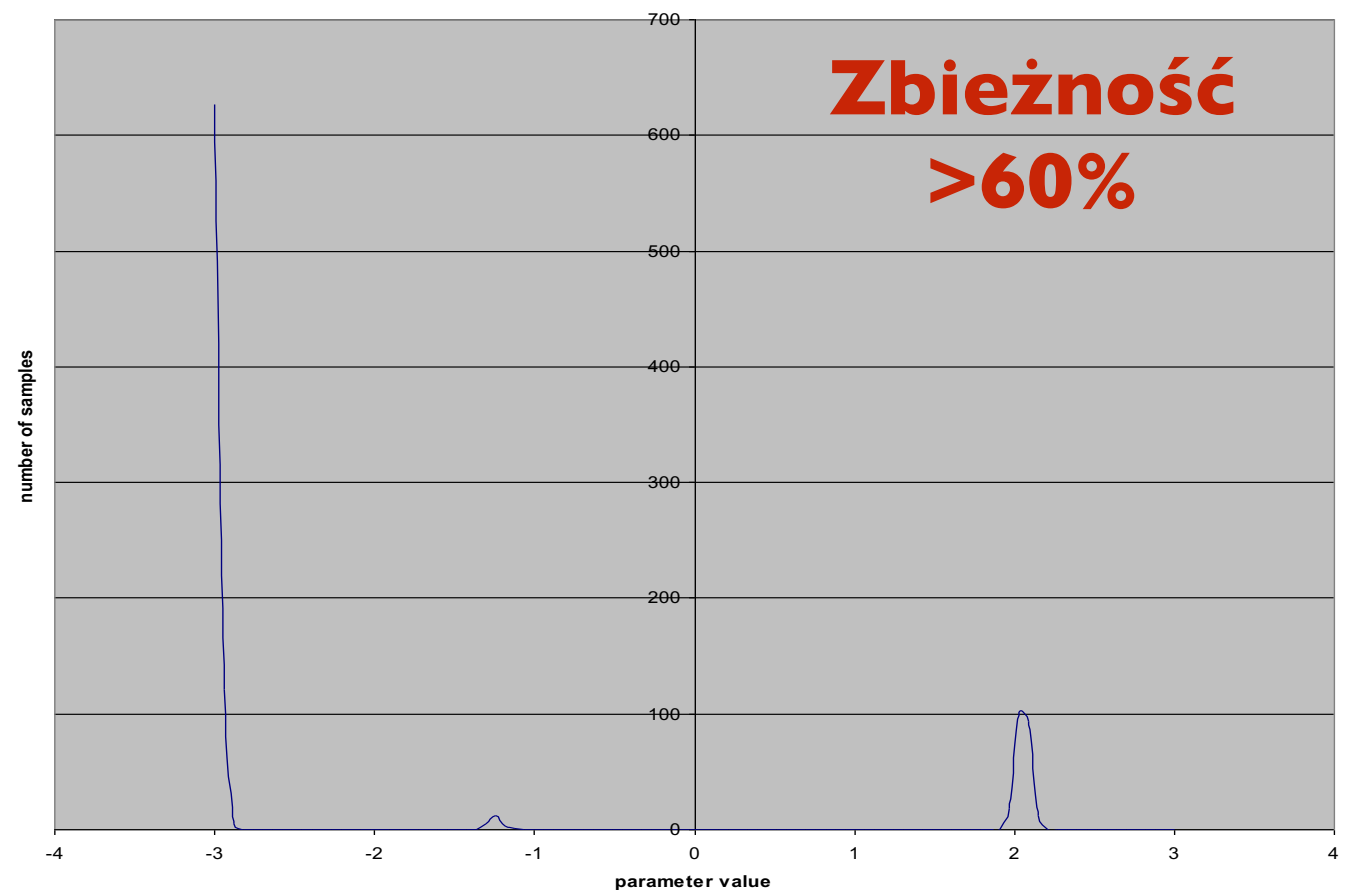


Figure 7. 2D plot of Schwefel's function.



Najlepszy „osobnik” w każdej z 1000 „populacji”

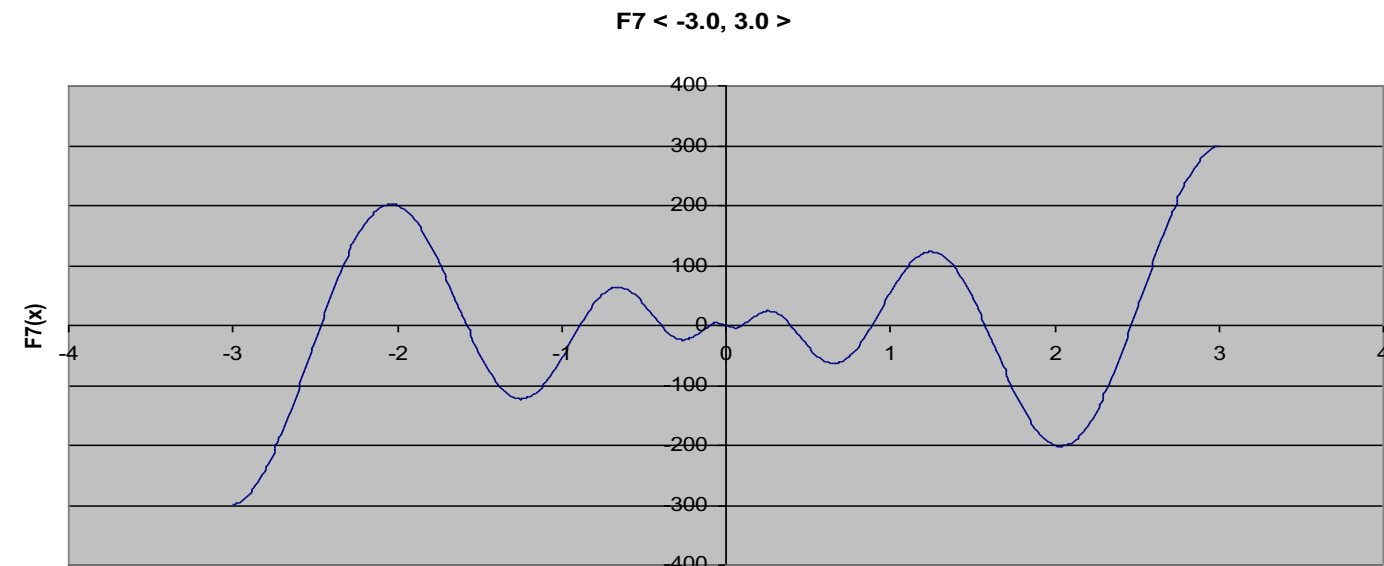


# Gdzie są minima?


Najbardziej czasochłonne jest wyliczenie  $\chi^2 \rightarrow$  zachowujemy obliczenia w każdym punkcie uzyskując informację o powierzchni  $\chi^2$

## QRepScan:

- wyszukuje wynik - zestaw elementów macierzowych o najniższym  $\chi^2$
- **poszukuje alternatywnych minimum**



Liczba „osobników”  
o danej wartości w „populacji”




# Gdzie są minima?


Najbardziej czasochłonne jest wyliczenie  $\chi^2$  → zachowujemy więc obliczenia w każdy punkcie uzyskując informacje o powierzchni  $\chi^2$

## QRepScan:



- wyszukuje wynik - zestaw elementów macierzowych o najniższym  $\chi^2$
- **poszukuje alternatywnych minimum**



Liczba „osobników”  
o danej wartości w „populacji”


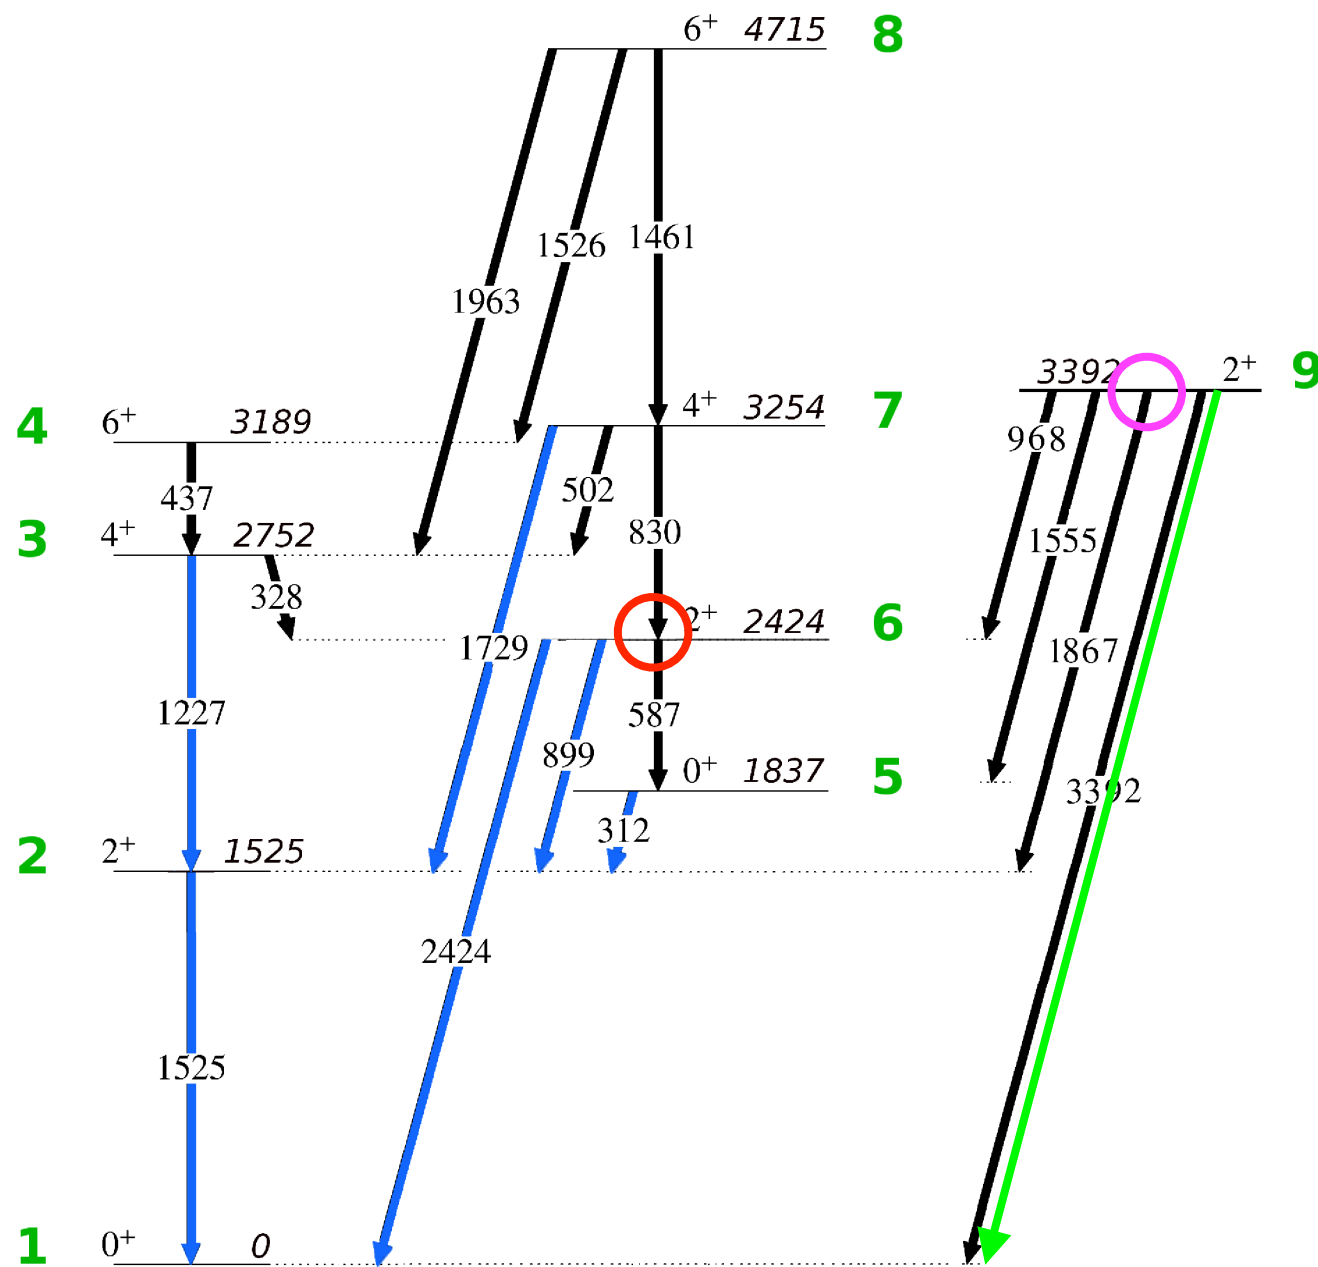


# Przypadek fizyczny: $^{42}\text{Ca}$





# Przypadek fizyczny: $^{42}\text{Ca}$



# Wyznaczenie niepewność pomiarowej

GOSIA:

+ całkowanie funkcji  $\exp(-\frac{1}{2} \chi^2(M))$

- przybliżone uwzględnienie korelacji między elementami macierzowymi

Wykorzystajmy skanowanie powierzchni  $\chi^2$  do geometrycznego wyznaczenia niepewności pomiarowej: kontur  $\chi_{\min}^2+1$




FIG. 9. Result of the  $\chi^2$  minimization for the  $\langle 0_1^+ || E2 || 2_1^+ \rangle$  and  $\langle 2_1^+ || E2 || 2_1^+ \rangle$  matrix elements in  $^{140}\text{Sm}$  obtained after the last iteration of step 4 of the fitting procedure using target normalization. Note that the final uncertainties of all matrix elements were obtained after one more iteration of step 3.


M. Klintefjord et al.,  
PHYSICAL REVIEW C **93**, 054303 (2016)

# Jakie są minima?

Najbardziej czasochłonne jest wyliczenie  $\chi^2$  → zachowujemy obliczenia w każdym punkcie uzyskując informacje o powierzchni  $\chi^2$

## QRepScan:

- wyszukuje wynik - zestaw elementów macierzowych o najniższym  $\chi^2$
- poszukuje alternatywnych minimum
- **separuje minima - klasteryzacja NBC**
- **redukuje liczbę punktów - MDR**
- **wyznacza kontur niepewności - FLA**



D.Piętak, Rozprawa doktorska, PW 2020

Shuigeng Zhou, Yue Zhao, Jihong Guan, Joshua Huang:

NBC: A Neighborhood-Based Clustering Algorithm.

Lecture Notes in Computer Science, Springer Berlin / Heidelberg, 2005



D.A.Piętak, J. Wojciechowski, P. J.Napiorkowski

*A Front Line Algorithm For Error Estimation In Data Sets With Nonuniform Sampling Distribution*

20th European Conference on Circuit Theory and Design (ECCTD), 2011

# Front Line Algorithm

test z funkcją F7 i próbkowaniem równomiernym



2,500 scale: 1,00000, 1,00000



D.A.Piętak, J. Wojciechowski, P. J.Napiorkowski

*A Front Line Algorithm For Error Estimation In Data Sets With Nonuniform Sampling Distribution*

20th European Conference on Circuit Theory and Design (ECCTD), 2011

# Front Line Algorithm



test z funkcją F7 i algorytmem genetycznym






# Front Line Algorithm

geometryczne wyznaczenie niepewności







# Porównanie: GOSIA vs JACOB



$^{132}\text{Ba}$

- Przypadek  $^{132}\text{Ba}$  ograniczony do 8 wymiarów (parametrów).
- **To nie jest jeszcze wynik fizyczny!**
- Jest to symulacja wykorzystująca rzeczywiste dane doświadczalne.

# Porównanie: GOSIA vs JACOB (AH)

Parametr Element macierzowy	Wartość	GOSIA	JACOB (AH)	
1	0,923	-3%,+4%	-2%,+2%	OK
2	0,267			NO
3	0,104	-	-	
4	1,235	-1%,+1%	-12%,+12%	?
5	1,033	-2%,+2%	-17%,+16%	?
6	0,021	-	-	
7	-1.495			NO
8	0,648	-6%,+7%	-10%,+10%	OK

# Algorytm genetyczny dla wzbudzeń kulombowskich

## Podsumowanie

- W analizie wzbudzeń kulombowskich zaimplementowano metodę minimalizacji z elementami „sztucznej inteligencji”.
- Połączenie algorytmu genetycznego i metody gradientowej daje najlepsze wyniki.
- Algorytm genetyczny oferuje dodatkowe funkcjonalności dla użytkownika i z niektórych już umiemy korzystać.
- Wyznaczanie niepewności pomiarowej wymaga dalszej walidacji na dobrych (niezbyt skomplikowanych) przypadkach fizycznych.
- Zastosowanie algorytmu genetycznego do wzbudzeń kulombowskich jest interesującym problemem badawczym także dla informatyków.

# Ludzie ...

## Wydział Elektroniki i Technik Informatycznych Politechniki Warszawskiej

- mgr inż. Daniel Andrzej Piętaś
- **prof. dr hab. Jacek Wojciechowski**
- dr hab. Piotr Bilski, prof. PW
- dr inż. Andrzej Pająk

## SLCJ

- lic. Wojciech Piątek

# ... i ich dzieła

- D. A. Pięta, *Implementacja algorytmu genetycznego do analizy danych z pomiarów wzbudzeń kulombowskich*, Praca dyplomowa, Politechnika Warszawska, 2008
- D.A.Pięta, P.J.Napiorkowski, Z.Walczak, J.Wojciechowski *Application of Genetic Algorithm with Real Representation to COULEX Data Analysis*, Proceedings of the Conference on Evolutionary Computation and Global Optimization Oficyna Wydawnicza Politechniki Warszawskiej, 2009
- Wojciech Piątek i Aleksandra Rubin *Projekt dyplomowy, Uniwersytet Kardynała Stefana Wyszyńskiego, 2010*  
W.Piątek, A.Rubin, J.Górecki, D.A.Pięta, P.J.Napiorkowski, HIL Annual Report 2010
- D.A.Pięta, J. Wojciechowski, P. J.Napiorkowski *A Front Line Algorithm For Error Estimation In Data Sets With Nonuniform Sampling Distribution* 20th European Conference on Circuit Theory and Design (ECCTD), 2011
- D.A.Pięta *Metody oceny jakości wyników eksperymentów wzbudzeń kulombowskich z wykorzystaniem algorytmu genetycznego.* Rozprawa doktorska, Politechnika Warszawska, Warszawa 2020