



Paweł Pijarski

Optymalizacja heurystyczna w ocenie warunków pracy i planowaniu rozwoju systemu elektroenergetycznego

MONOGRAFIE

Optymalizacja heurystyczna w ocenie warunków pracy i planowaniu rozwoju systemu elektroenergetycznego

Monografie – Politechnika Lubelska



Politechnika Lubelska
Wydział Elektrotechniki i Informatyki
ul. Nadbystrzycka 38A
20-618 Lublin

Paweł Pijarski

Optymalizacja heurystyczna w ocenie warunków pracy i planowaniu rozwoju systemu elektroenergetycznego



Wydawnictwo Politechniki Lubelskiej
Lublin 2019

Recenzent:

prof. dr hab. inż. Marian Sobierajski, Politechnika Wrocławska

Publikacja wydana za zgodą Rektora Politechniki Lubelskiej

© Copyright by Politechnika Lubelska 2019

ISBN: 978-83-7947-349-6

Wydawca: Wydawnictwo Politechniki Lubelskiej
www.biblioteka.pollub.pl/wydawnictwa
ul. Nadbystrzycka 36C, 20-618 Lublin
tel. (81) 538-46-59

Druk: TOP Agencja Reklamowa Agnieszka Łuczak
www.agencjatop.pl

Elektroniczna wersja książki dostępna w Bibliotece Cyfrowej PL www.bc.pollub.pl
Nakład: 50 egz.

Spis Treści

Wykaz ważniejszych oznaczeń	9
Wstęp	11
1. Dlaczego heurystyka?	12
2. Metody optymalizacji	15
2.1 Sformułowanie zagadnienia	15
2.2 Optymalizacja klasyczna	18
2.2.1 Uwagi wstępne	18
2.2.2 Optymalizacja nieliniowa z ograniczeniami	18
2.2.3 Optymalizacja liniowa z ograniczeniami	25
2.2.4 Optymalizacja kombinatoryczna z ograniczeniami	29
2.3 Optymalizacja heurystyczna	31
2.3.1 Algorytmy	31
2.3.2 Sposoby uwzględniania ograniczeń	34
3. Nowa autorska metoda optymalizacji heurystycznej – Algorytm Innowacyjnego Artylerzysty (Algorithm of the Innovative Gunner – AIG)	39
3.1 Uwagi wstępne	39
3.2 Inspiracja	40
3.3 Opis „algorytmu innowacyjnego artylerzysty”	42
3.3.1 Rzut ukośny – fizyczne podstawy balistyki	42
3.3.2 Przykład zastosowania metody AIG do wyznaczenia optymalnego kąta strzału	44
3.3.3 Uogólniony algorytm AIG	46
3.4 Strojenie algorytmu	49
3.4.1 Losowanie kątów	49
3.4.2 Zmiany zakresu losowania kątów	49
4. Wybrane testowe funkcje celu z ograniczeniami, dotyczące różnych problemów rzeczywistych z dziedziny mechaniki	53
4.1 Problem projektowania sprężyny	53
4.2 Problem projektowania zbiornika ciśnieniowego	55
4.3 Problem konstrukcji spawanej belki	56
4.4 Problem konstrukcji przekładni zębatej	57
4.5 Problem wagi konstrukcji kratownicy	58
4.6 Problem projektowania belki wspornikowej	60
4.7 Problem konstrukcji dwuteownika	61
4.8 Problem konstrukcji reduktora prędkości	62
5. Wybrane matematyczne testowe funkcje celu	65
5.1 Goldstein-Price function – F1	66
5.2 Rosenbrock’s function – F2	66
5.3 De Jong’s function 5 – F3	67
5.4 Schaffer’s function 6 – F4	68
5.5 De Jong’s function 7 – F5	68

5.6	Griewangk's function – F6	69
5.7	Ackley's function – F7	70
5.8	Egg crate function – F8	70
5.9	Michalewicz function – F9	71
5.10	Rastrigin's function – F10	72
5.11	Langermann's function – F11	72
5.12	Shubert's function – F12	73
5.13	Holder's table function – F13	74
5.14	Drop's wave function – F14	74
5.15	Bukin's function – F15	75
5.16	Funkcja celu z ograniczeniami równościowymi – F16	76
5.17	Funkcja celu z ograniczeniami równościowymi i nierównościowymi jednocześnie – F17	76
5.18	Porównanie wyników obliczeń	78
5.19	Dodatkowa analiza porównawcza	80
6.	Zagadnienia optymalizacyjne w elektroenergetyce	85
6.1	Uwagi wstępne	85
6.2	Metody i narzędzia obliczeniowe	86
7.	Optymalne wartości mocy źródeł z punktu widzenia różnych kryteriów związanych z pracą SEE	89
7.1	Opis sieci testowej	89
7.2	Dopasowanie poziomu mocy generowanej do możliwości przesyłowych gałęzi (linii i transformatorów)	95
7.3	Wygaszanie planów budowy niektórych źródeł w celu przyłączenia wybranych.	105
7.4	Możliwości przyłączania nowych źródeł do systemu elektroenergetycznego.	109
8.	Optymalny dobór urządzenia kompensacyjnego dla farmy wiatrowej przyłączonej do sieci elektroenergetycznej linią kablową	113
8.1	Wprowadzenie	113
8.2	Opis sieci testowej	117
8.3	Obliczenia	120
9.	Optymalizacja rozptyłów mocy biernej w systemie elektroenergetycznym	127
9.1	Wprowadzenie	127
9.2	Opis sieci testowej	127
9.3	Obliczenia optymalizacyjne	128
10.	Minimalizacja różnicy kątów fazorów napięcia przy załączaniu linii elektroenergetycznych	145
10.1	Wprowadzenie	145
10.2	Opis sieci testowej	146
10.3	Obliczenia	147

11.Optymalny dobór parametrów charakterystyk $P(U)$ i $Q(U)$ falowników instalacji fotowoltaicznych.....	151
11.1 Wprowadzenie	151
11.2 Obliczenia optymalizacyjne.....	153
12.Optymalizacja wyboru punktów podziału w sieci średniego napięcia	163
12.1 Wprowadzenie	163
12.2 Obliczenia.....	163
13.Optymalne sterowanie urządzeniami do regulacji przepływów mocy czynnej.....	169
13.1 Minimalizacja nieplanowanych przepływów mocy	169
13.1.1 Opis sieci testowej	169
13.1.2 Obliczenia.....	170
13.2 Odciażanie przeciążonych elementów SEE.....	171
14.Minimalizacja kosztów bilansowania zapotrzebowania na moc w SEE.....	177
14.1 Wprowadzenie	177
14.2 Opis sieci testowej.....	177
14.3 Obliczenia.....	178
Podsumowanie	183
Bibliografia	187

Wykaz ważniejszych oznaczeń

ERO	– Ekonomiczny Rozdział Obciążeń
SEE	– System Elektroenergetyczny
KSE	– Krajowy System Elektroenergetyczny
DSJW	– Dobór Składu Jednostek Wytwórczych
OPF	– ang. <i>Optimal Power Flow</i>
SCOPF	– ang. <i>Security Constrained Optimal Power Flow</i>
AIG	– Algorytm Innowacyjnego Artylerzysty (ang. <i>Algorithm of the Innovative Gunner</i>)
FW	– farma wiatrowa
FPV	– farma fotowoltaiczna
OZE	– odnawialne źródło energii
WN	– wysokie napięcie
NN	– najwyższe napięcie
JWCD	– jednostka wytwórcza centralnie dysponowana
PPM	– moduł parku energii (ang. <i>Power Park Module</i>)
FSR	– ang. <i>Fixed Shunt Reactor</i>
VSR	– ang. <i>Variable Shunt Reactor</i>
SVC	– ang. <i>Static Var Compensation</i>
STATCOM	– ang. <i>Static Compensator</i>
FACTS	– ang. <i>Flexible AC Transmission Systems</i>
OLTC	– ang. <i>On Load Tap Changer</i>
LMP	– krótkookresowa cena węzłowa (ang. <i>Locational Marginal Price</i>)
NFLT	– ang. <i>No Free Lunch Theorem</i>
F_c	– funkcja celu
D	– obszar dopuszczalny
$\hat{F}_c(x)$	– nowa funkcja celu z karą
x	– wektor zmiennych decyzyjnych
y	– wektor zmiennych niezależnych
z	– wektor zmiennych zależnych
g	– wektor ograniczeń równościowych
h	– wektor ograniczeń nierównościowych
L	– funkcja Lagrange’a
λ	– mnożnik Lagrange’a
μ	– mnożnik Kuhna-Tuckera
r	– parametr kary
$T(s, r)$	– funkcja kary – klasyczna metoda optymalizacji

$B(v)$	– forma kwadratowa
A	– macierz ograniczeń nierównościowych – metoda Simplex
B	– wektor wyrazów wolnych przy ograniczeniach nierównościowych – metoda Simplex
x_B	– wektor zmiennych bazowych – metoda Simplex
x_N	– wektor zmiennych niebazowych – metoda Simplex
δ	– wektor kątów napięć
$\hat{Z}_{ij}$	– element ij macierzy impedancyjnej
Z_{k-l}	– impedancja gałęzi łączącej węzły k oraz l
U_n	– wartość napięcia znamionowego
$P(x)$	– funkcja kary – ograniczenia w metodach heurystycznych
$f_h(\gamma)$	– funkcja odpowiadającą oddziaływaniu czynników zakłócających
$g(\xi)$	– funkcja korekcyjna
ξ	– argumenty funkcji korekcyjnej (kąty korekcyjne)
α, θ	– kąty korekcyjne
x^i	– wartość i -tej zmiennej decyzyjnej
H	– wysokość pocisku w odległości d od strzelca
δ	– kąt strzału lub przekładnia katowa, do regulacji skośnej
k	– współczynnik oporu powietrza
v_0	– prędkość początkowa
d	– odległość od celu
g	– przyspieszenie ziemskie
$P(U)$	– charakterystyka mocy czynnej w funkcji napięcia dla falownika
$Q(U)$	– charakterystyka mocy biernej w funkcji napięcia dla falownika
U_G	– wektor napięć zadanych w węzłach wytwórczych
v_T	– wektor przekładni transformatorów regulacyjnych
Q_k	– wektor mocy biernych kompensatorów zainstalowanych w wybranych węzłach sieci.
δ_{ij}	– różnica kątów pomiędzy węzłami i oraz j
δ_{ijwym}	– wymagana różnica kątów pomiędzy węzłami i oraz j
c	– cena ofertowa energii elektrycznej
$\partial K(P_G)$	– minimalna zmiana kosztu bilansowania zapotrzebowania SEE
∂P_{Lj}	– zmiana mocy odbieranej w węźle j
P_{i-j}	– moc wymiany pomiędzy obszarami i oraz j

Wstęp

Kilkunastoletnie doświadczenia autora, związane z realizacją ekspertyz oceniających oddziaływanie źródeł wytwórczych na system elektroenergetyczny oraz z wykonaniem projektów badawczych i różnych innych prac o charakterze analitycznym, wskazują na występowanie w elektroenergetyce wielu problemów, które mogą być rozwiązane poprzez zastosowanie optymalizacji. Powszechnie wiadomo, że optymalizacja polega na znalezieniu najlepszego rozwiązania z punktu widzenia przyjętego kryterium (funkcji celu). Istnieje wiele metod optymalizacji, takich jak metody klasyczne, heurystyczne, hybrydowe, statyczne, dynamiczne.

Poszukiwanie rozwiązań konkretnych problemów może opierać się na doświadczeniu, intuicji i wiedzy inżynierskiej, jednak nie zawsze daje to oczekiwane rezultaty i gwarancję uzyskania optymalnego wyniku. Chcąc np. odciążać przeciążone linie elektroenergetyczne w określonym obszarze sieci, można oczywiście zainwestować w nowe połączenia lub kosztowne modernizacje, ale czy te zabiegi będą ekonomicznie uzasadnione i zagwarantują minimalne koszty? Nie zawsze i nie w każdych warunkach. Nieraz lepszym rozwiązaniem, z punktu widzenia ekonomicznego, jest odpowiednia konfiguracja struktury sieci lub rozkład generacji wyznaczony z wykorzystaniem konkretnego aparatu matematycznego. Zabieg ten bywa o wiele tańszy i w niektórych przypadkach bardziej skuteczny w stosunku do istniejącego stanu SEE. Pojęcie optymalizacji w systemie elektroenergetycznym jest znane od dawna, tak samo jak rozwiązywanie zadania rozprężowego. Na początku dotyczyło ono głównie poszukiwania takiego rozdziału wytwarzanej mocy na pracujące jednostki wytwórcze, aby sumaryczny koszt wytwarzania był minimalny. Problem ten określono jako zagadnienie ERO (Ekonomiczny Rozdział Obciążeń). Rozwiązanie zadania ERO było możliwe pod warunkiem znajomości charakterystyk kosztów wytwarzania poszczególnych źródeł.

Obecnie zadania optymalizacyjne w SEE często występują pod nazwą OPF (ang. *Optimal Power Flow*) lub (po uwzględnieniu kryterium „N-1”) SCOPF (ang. *Security Constrained Optimal Power Flow*). Aby uświadomić sobie trudność w stworzeniu efektywnego narzędzia komputerowego do rozwiązywania powyższych zagadnień należy podkreślić, że tylko niektóre programy komercyjne do analizy SEE zawierają narzędzia tego typu. Mało tego, wiele z tych programów opiera się na linearyzacji zagadnienia, co jest pewnym uproszczeniem i może niekiedy prowadzić do wyciągania błędnych wniosków, szczególnie przy analizie dużych sieci. Trudności obliczeniowe, na jakie natrafił autor przy wykonywaniu prac związanych z analizą systemu elektroenergetycznego, skłoniły do poszukiwania nowych metod i alternatywnych rozwiązań. Niniejsza monografia nie jest poświęcona udowadnianiu wyższości heurystyki nad klasycznymi metodami optymalizacji. Jej celem jest raczej zwrócenie uwagi na nowe metody i możliwości wykorzystania ich zalet i specyficznych właściwości. Oczywiście nie należy ich rozumieć jako antidotum na wszystkie problemy obliczeniowe związane z poszukiwaniem rozwiązania optymalnego, tylko środek z którego można skorzystać, gdy zawiodą inne sposoby.

1. Dlaczego heurystyka?

Stosowanie metod klasycznych (optymalizacja liniowa i nieliniowa z ograniczeniami) jest uzasadnione w przypadkach, gdy znana jest postać funkcji celu oraz najczęściej wtedy, gdy występuje jedno optimum. Nie zawsze jednak funkcja celu jest jednoznacznie określona. Często obszar tworzący dziedzinę funkcji jest zbiorem liczb całkowitych, co wynika ze specyfiki problemu. Ponadto czasami nie jest znana pochodna funkcji celu, co więcej, funkcja celu może być w wielu punktach nieciągła. Niektóre ograniczenia mogą być niejawne i po ich włączeniu do funkcji celu (klasyczna metoda uwzględniania ograniczeń) nie można przewidzieć, jaki kształt przyjmuje powstała w ten sposób nowa funkcja celu, która podlega optymalizacji. Kolejną przeszkodą w stosowaniu metod klasycznych jest występowanie wielu optimów, czy możliwość wystąpienia rozbieżnego procesu iteracyjnego.

Ponadto problemem może być wymiar zadania, w szczególności rozległy system elektroenergetyczny, złożony z kilku tysięcy elementów, tak jak np. KSE (Krajowy System Elektroenergetyczny). Programy komercyjne zawierające opcje optymalizacyjne (np. DigSILENT, PowerFactory, PowerWorld Simulator) mają trudności z uzyskaniem rozwiązania dla tak dużej sieci. Wynika to z faktu, że w stanach normalnych, z pewnych względów, nie są spełnione niektóre ograniczenia i dany program nie jest w stanie sobie z tym poradzić.

Jeżeli na powyższe nałożyć się konieczność spełnienia kryterium „ $N-1$ ”, czy inne warunki, narzucane z góry przez operatorów systemu, wówczas wzrasta rozmiar zagadnienia i komplikuje się ono na tyle, że metody klasyczne stają się mniej efektywne lub wręcz nieodpowiednie do jego rozwiązania. Biorąc pod uwagę powyższe trudności, zastosowanie heurystyki w elektroenergetyce wydaje się być uzasadnione.

Metody heurystyczne pozwalają rozwiązywać różnego rodzaju zadania, które nie mogą być rozwiązane metodami klasycznymi lub zastosowanie tych metod jest zbyt czasochłonne i pracochłonne. W porównaniu z metodami klasycznymi, metody heurystyczne charakteryzują się tym, że nie wymagają znajomości postaci pochodnej funkcji celu, są odporne na nieciągłości tej funkcji oraz na „utknięcie” procesu obliczeniowego w lokalnym minimum. W przypadku wystąpienia rozbieżnego procesu iteracyjnego heurystyka jest w stanie poradzić sobie z tym problemem w ten sposób, że dane rozplływowe można wczytać ponownie w dowolnym momencie procesu obliczeniowego. Nie traci się wówczas najlepszego, ostatecznie znalezione rozwiązanie, bowiem wektor ten jest pamiętany na każdym etapie trwania obliczeń. Metoda klasyczna musiałaby w takim przypadku zostać przerwana, a obliczenia rozpoczęte na nowo.

W przypadku dużych sieci, np. KSE optymalizacja stosująca metody heurystyczne może startować z punktu niedopuszczalnego (dodawana jest wtedy kara za przekroczenie ograniczeń), aby w trakcie obliczeń znaleźć się wewnątrz obszaru stanowiącego dziedzinę funkcji.

Metody heurystyczne są obecnie coraz częściej wykorzystywane (nie tylko w elektroenergetyce), jako nowoczesne metody bezgradientowe do rozwiązywania zadań optymalizacji nieliniowej z ograniczeniami, o olbrzymim potencjale możliwości. Są one nieustannie rozwijane, o czym świadczą nowe publikacje [231–242]. W tab. 1.1 przedstawiono podstawowe właściwości metod heurystycznych:

Tab. 1.1 Najważniejsze właściwości metod heurystycznych [21–52]

Lp.	Właściwości
1	Losowość, która umożliwia przeszukiwanie całej przestrzeni rozwiązań
2	Możliwość zastosowania do problemów o dowolnym wymiarze
3	Możliwość zastosowania do problemów „silnie nieliniowo zależnych”
4	Uniwersalność, która objawia się tym, że algorytm nie jest powiązany z właściwościami danego problemu
5	Możliwość zapamiętania najlepszego dotychczas znalezionej rozwiązania
6	Przy niektórych metodach istnieje możliwość sterowania algorytmem w sposób zwiększający prawdopodobieństwo znalezienia optimum globalnego
7	Przy niektórych metodach (np. rój cząstek) istnieje możliwość wykorzystania jednego zestawu parametrów sterujących procesem obliczeniowym do rozwiązywania wielu problemów
8	Przy niektórych metodach (np. symulowane wyżarzanie) istnieje możliwość wyboru gorszego rozwiązania podczas obliczeń, co zwiększa prawdopodobieństwo znalezienia rozwiązania globalnego
9	Niezależność od dziedziny funkcji – algorytm może być stosowany, gdy przestrzeń poszukiwań jest dyskretna, ciągła lub gdy istnieją punkty nieciągłości funkcji.
10	Możliwość zastosowania i dostosowania do problemów nieuporządkowanych i chaotycznych

Wadą metod heurystycznych jest stosunkowo długi czas uzyskania akceptowalnego rozwiązania oraz to, że rozwiązanie globalne znalezione jest zawsze z pewnym prawdopodobieństwem, chociaż istnieją dowody na zbieżność globalną algorytmów, np. symulowanego wyżarzania. W celu zwiększenia efektywności obliczeń, można również łączyć różne metody. Często jest tak, że za pomocą jednej z metod optymalizacji heurystycznej dokonujemy „zgrubnego” przeszukania przestrzeni rozwiązań, natomiast w ostatniej fazie algorytmu, zastosowana zostaje metoda klasyczna, która pozwala dokładnie określić rozwiązanie. Takie postępowanie jest odpowiednie, np. w przypadku, gdy funkcja celu posiada wiele optimum lokalnych, nieznacznie różniących się od

siebie. Wtedy metoda heurystyczna zapewnia znalezienie obszaru, w którym możemy się spodziewać optimum globalnego, natomiast metoda klasyczna pozwala je znaleźć z dużym prawdopodobieństwem.

Generalnie rzecz biorąc, wyróżnić można cztery powody, dla których heurystyka jest coraz bardziej powszechna: prostota, elastyczność, dowolność w tworzeniu nowych algorytmów oraz unikanie lokalnych optimów. Źródła inspiracji w powstawaniu nowych metod mogą być różne. Rozwiązywanie zadań optymalizacyjnych, należących do różnych dziedzin nauki, nie wymaga gruntownych zmian algorytmów. Praktycznie każda funkcja celu może podlegać optymalizacji, bez konieczności sprawdzania jej ciągłości czy różniczkowalności. Ze względu na losową naturę metod heurystycznych, istnieje duże prawdopodobieństwo znalezienia optimum globalnego. Zalety i właściwości heurystyki, przedstawione powyżej, uzasadniają merytorycznie jej zastosowanie w elektroenergetyce.

W ostatnich latach w wielu opracowaniach pojawia się termin metaheurystyka (*meta* z greckiego oznacza „ponad”). Można powiedzieć, że metaheurystyka to reguły dotyczące sposobu generowania reguł – takich, które mogą najbardziej pomóc w poszukiwaniu dobrego rozwiązania. Metaheurystykami nazywa się, więc ramy i zasady generowania reguł dla konkretnych algorytmów heurystycznych. W ramach jednej metaheurystyki można zawsze zaproponować przynajmniej kilka algorytmów heurystycznych, będących wariantami pewnego ogólnego podejścia. Przy takim rozumieniu heurystyki można stwierdzić, że istotne fragmenty rozważań zawartych w prezentowanej pracy dotyczą właśnie tego obszaru jednak, aby zachować spójność tekstu, autor pozostał przy stosowaniu terminu heurystyka.

2. Metody optymalizacji

2.1 Sformułowanie zagadnienia

Jak już wcześniej wspomniano, historia optymalizacji w elektroenergetyce sięga problemów związanych z rozwiązywaniem zadania ERO (Ekonomiczny Rozdział Obciążeń), DSJW (Dobór Składu Jednostek Wytwórczych), rozdziału mocy biernej na źródła czy doboru przekładni transformatorów regulacyjnych (optymalizacji napięć węzłowych) [131, 132].

Rozwiązanie zadania ERO było możliwe pod warunkiem znajomości charakterystyk kosztów wytwarzania poszczególnych źródeł. Charakterystyki te mają z reguły postać nieliniową. Zadanie minimalizacji nieliniowej funkcji celu z ograniczeniem równościowym rozwiązuje się tworząc funkcję Lagrange'a, z mnożnikami λ . Rozwiązanie zadania ERO komplikuje się znacznie przy uwzględnianiu ograniczeń typu nierównościowego (minima techniczne i maksymalne wartości mocy źródeł) oraz równościowego (bilansowe ograniczenia równościowe mocy w systemie z uwzględnieniem strat w całej sieci). Obecnie, zadania optymalizacyjne w SEE często występują pod nazwą OPF (*Optimal Power Flow*) lub (po uwzględnieniu kryterium „N-1”) SCOPF (*Security Constrained Optimal Power Flow*).

Chcąc zapisać i rozwiązać pełne zadanie optymalizacyjne należy uwzględnić wszystkie warunki pracy sieci przesyłowej i związane z nimi ograniczenia [134, 135, 137, 139, 140, 141, 142, 144, 148, 149, 160, 169]. Konieczne staje się wprowadzenie oznaczeń wektorów:

1. Wektor zmiennych decyzyjnych $\mathbf{x}$ (obejmujący m.in. moce czynne elektrowni $\mathbf{P}_G$, regulowane moduły napięć $\mathbf{U}_G$, regulowane moce bierne $\mathbf{Q}$ (baterii kondensatorów, dławików, układów SVC, STATCOM), regulowane przekładnie transformatorów $\mathbf{v}_T$, intencjonalne lub losowe zmiany konfiguracji sieci $\mathbf{st}$)

$$\mathbf{x} = [\mathbf{P}_G, \mathbf{U}_G, \mathbf{Q}, \mathbf{v}_T, \mathbf{st}] \quad (2.1)$$

2. Wektor zmiennych niezależnych $\mathbf{y}$ (obejmujący moce odbierane w węzłach)

$$\mathbf{y} = [\mathbf{P}_L, \mathbf{Q}_L] \quad (2.2)$$

3. Wektor zmiennych zależnych $\mathbf{z}$ (jednoznacznie opisujący napięcia węzłowe i ich kąty)

$$\mathbf{z} = [\mathbf{U}, \boldsymbol{\delta}] \quad (2.3)$$

Mając opisane wektory $\mathbf{x}$, $\mathbf{y}$ oraz $\mathbf{z}$, zadanie optymalizacyjne (OPF – *Optimal Power Flow*) można sformułować w następujący sposób:

- funkcja celu – poszukiwany jest np. wektor zmiennych decyzyjnych $\mathbf{x}$ zapewniający jej minimum;

$$F_c(\mathbf{x}, \mathbf{y}, \mathbf{z}) \rightarrow \min \quad (2.4)$$

- wektor ograniczeń równościowych zapewniający w szczególności spełnienie bilansu mocy dla wszystkich węzłów sieci oraz utrzymanie na określonym poziomie bilansu wymiany mocy z zagranicą (warunek bilansu mocy z zagranicą sformułowany w postaci równościowej może być bardzo trudny do spełnienia, dlatego też rozpatrywany jest często jako warunek nierównościowy);

$$\mathbf{g}(\mathbf{x}, \mathbf{y}, \mathbf{z}) = \mathbf{0} \quad (2.5)$$

- wektor ograniczeń nierównościowych zapewniający utrzymanie wartości elementów wektora zmiennych zależnych oraz wektora zmiennych decyzyjnych w zakresie określonym przez wymagania techniczne;

$$\mathbf{h}(\mathbf{x}, \mathbf{y}, \mathbf{z}) \geq \mathbf{0} \quad (2.6)$$

Jako funkcje celu (w elektroenergetyce) można rozpatrywać następujące, wybrane zagadnienia:

- ekonomiczny rozdział obciążeń,
- dobór składu jednostek wytwórczych,
- rozdział mocy biernej na źródła,
- optymalizacja rozpyływu mocy biernej,
- optymalny dobór przekładni transformatorów regulacyjnych,
- minimalizacja strat mocy czynnej w systemie,
- wyznaczanie możliwości przyłączeniowych SEE
- dynamiczne dopasowanie poziomu generacji do możliwości przesyłowych gałęzi (linii i transformatorów),
- optymalny wybór punktów podziału w sieci SN,
- minimalizacja różnicy kątów fazorów napięcia przy załączaniu linii elektroenergetycznych,
- optymalizacja nastaw przesuwników fazowych,
- optymalne planowanie struktury sieci z punktu widzenia likwidacji przeciążeń gałęzi,
- optymalne planowanie struktury sieci z punktu widzenia minimalizacji mocy zwarciovych,
- optymalne rozmieszczenie stacji rozdzielczych,

- maksymalizacja wskaźnika wykorzystania infrastruktury sieciowej; przez wskaźnik wykorzystania infrastruktury sieciowej należy rozumieć sumę różnic pomiędzy dopuszczalnym prądem gałęzi sieci, a ich prądem rzeczywistym.

Za ograniczenia (w elektroenergetyce) przyjmuje się z reguły:

- równania bilansowe, które muszą być spełnione dla każdego węzła sieci,
- równania zapewniające utrzymanie bilansu wymiany mocy z zagranicą na zadanym poziomie,
- ograniczenia dla wartości napięć w węzłach sieci,
- ograniczenia dla elementów wektora sterującego, tj. mocy czynnych i biernych generowanych w węzłach, wynikają z mocy znamionowych generatorów przyłączonych do rozpatrywanego węzła i ich właściwości ruchowych odniesionych do mocy znamionowych,
- ograniczenia wynikające z możliwości przesyłowych elementów sieci (linii i transformatorów) wynikają z maksymalnej wartości prądu, która nie powoduje w tych elementach negatywnych skutków termicznych; dla transformatorów wartości te wynikają z mocy znamionowej, natomiast dla linii (w szczególności dla linii napowietrznych) ich oszacowanie może podlegać zmianom, wynikającym z uwzględniania warunków zewnętrznych (temperatury, wiatru, nasłonecznienia); minimalne zróżnicowanie obejmuje podział na obciążalność letnią i zimową,
- uwzględnienie kryterium „N-1” (SCOPF, ang. *security constrained optimal power flow*); dla SEE niezwykle ważna jest zdolność do niezawodnej realizacji funkcji wytwórczych i przesyłowych także w warunkach awaryjnych; w praktyce sprawdzanie, czy zdolność ta jest zachowana w stosunku do sieci systemu wykonuje się poprzez sprawdzenie spełnienia kryterium „N-1”; liczba n oznacza liczbę gałęzi przyłączonych do rozpatrywanego węzła; spełnienie kryterium „N-1” ma miejsce wtedy, gdy wyłączenie (pojedynczo) każdej z tych gałęzi nie doprowadzi do przekroczenia dopuszczalnych parametrów „napięciowo-prądowych” zarówno w tym węźle, jak i w całej sieci; zasada musi być spełniona dla wszystkich węzłów sieci, z wyłączeniem węzłów zasilanych promieniowo, dla których spełnione być nie może.

W związku z powyższym, możliwe zagadnienia optymalizacyjne w elektroenergetyce, dzielą się na:

- zadania optymalizacji liniowej z ograniczeniami,
- zadania optymalizacji nieliniowej z ograniczeniami,
- zadania optymalizacji kombinatorycznej z ograniczeniami.

Wszelkie inne problemy stanowią pochodną wyżej wymienionych, lub są ich kompilacją.

Do rozwiązywania problemów z dziedziny elektroenergetyki można stosować zarówno metody klasyczne jak i heurystyczne, opisane w kolejnych rozdziałach. Należy tutaj zwrócić uwagę na fakt, że część z nich, jako nietypowe, mogą być rozwiązywane tylko za pomocą heurystyki i takim poświęcona jest niniejsza monografia. Oczywiście zawsze jest możliwość linearyzacji zagadnienia, ale prowadzi to z reguły do zbyt daleko idących uproszczeń, a nawet do uzyskania błędnych, nieakceptowalnych w praktyce wyników.

2.2 Optymalizacja klasyczna

2.2.1 Uwagi wstępne

Optymalizacja jest działaniem polegającym na znalezieniu punktu, w którym funkcja celu osiąga optimum (minimum lub maksimum). Zadanie to nie jest łatwe, w szczególności, gdy występują ograniczenia. Rzeczywiste problemy, np. z dziedziny elektroenergetyki, charakteryzują się z reguły różnego typu ograniczeniami, zarówno równościowymi jak i nierównościowymi. Funkcja celu, ponadto, może być liniowa jak i nieliniowa. W związku z powyższym istnieją różne metody rozwiązywania zadań optymalizacji, uzależnione od rodzaju problemu. Niniejszy rozdział poświęcony jest metodom klasycznym, ogólnie programowaniu liniowemu i nieliniowemu z uwzględnieniem ograniczeń.

2.2.2 Optymalizacja nieliniowa z ograniczeniami

Zagadnienia omawiane w niniejszym rozdziale należą do zadań optymalizacji nieliniowej z ograniczeniami równościowymi i nierównościowymi.

– uwzględnianie ograniczeń równościowych

W przypadku występowania tylko ograniczeń równościowych $g(x)$ zadanie to można rozwiązać za pomocą tzw. funkcji Lagrange'a o postaci [4, 6, 7, 10, 12, 14, 15, 16]:

$$L(x, \lambda) = F_c(x) + \sum_{i=1}^n \lambda_i \cdot g_i(x) \quad (2.7)$$

gdzie :

$\lambda = (\lambda_1, \lambda_2, \dots, \lambda_n)$ – n -elementowy wektor mnożników Lagrange'a,

$x = (x_1, x_2, \dots, x_m)$ – poszukiwany punkt – optimum, ogólnie rzecz biorąc wektor zmiennych decyzyjnych,

$F_c(x)$ – pierwotna funkcja celu,

$g_i(x) = 0$ – ograniczenia równościowe, $i = 1, 2, \dots, n$.

Warunkami koniecznymi (zwanymi warunkami Lagrange'a) istnienia ekstremum, nowo powstałej funkcji celu, jest zerowanie się jej pochodnych cząstkowych:

$$\begin{cases} \left(\frac{\partial L}{\partial x_k} \right)_{\hat{x}, \hat{\lambda}} = 0, & k=1, \dots, m \\ \left(\frac{\partial L}{\partial \lambda_i} \right)_{\hat{x}} = 0, & i=1, \dots, n \end{cases} \quad (2.8)$$

gdzie :

$\hat{x}, \hat{\lambda}$ – stanowią punkty, w których zarówno funkcja $F_c(\mathbf{x})$ jak i $L(\mathbf{x}, \boldsymbol{\lambda})$ osiągają ekstremum warunkowe.

Warunkami dostatecznymi istnienia ekstremum warunkowego funkcji Lagrange’a jest dodatnio lub ujemnie określona forma kwadratowa postaci

$$B(\mathbf{v}) = \sum_{k=1}^m \sum_{k'=1}^m \left(\frac{\partial^2 L}{\partial x_k \partial x_{k'}} \right)_{\hat{x}, \hat{\lambda}} \cdot v_k \cdot v_{k'} \quad (2.9)$$

przy spełnieniu warunków:

$$\sum_{k=1}^m \left(\frac{\partial g_i}{\partial x_k} \right)_{\hat{x}} \cdot v_k = 0, \quad i=1, \dots, n \quad (2.10)$$

Oznaczając $\mathbf{v} = [v_1, \dots, v_k]^T$ można formę kwadratową $B(\mathbf{v})$ zapisać w postaci:

$$B(\mathbf{v}) = \mathbf{v}^T \cdot \left(\nabla_{xx}^2 L \right)_{\hat{x}, \hat{\lambda}} \cdot \mathbf{v} \quad (2.11)$$

Macierzą tej formy jest macierz symetryczna:

$$\left(\nabla_{xx}^2 L \right)_{\hat{x}, \hat{\lambda}} = \begin{bmatrix} \left(\frac{\partial^2 L}{\partial x_1} \right)_{\hat{x}, \hat{\lambda}} & \left(\frac{\partial^2 L}{\partial x_1 \partial x_2} \right)_{\hat{x}, \hat{\lambda}} & \dots & \left(\frac{\partial^2 L}{\partial x_1 \partial x_m} \right)_{\hat{x}, \hat{\lambda}} \\ \left(\frac{\partial^2 L}{\partial x_2 \partial x_1} \right)_{\hat{x}, \hat{\lambda}} & \left(\frac{\partial^2 L}{\partial x_2} \right)_{\hat{x}, \hat{\lambda}} & \dots & \left(\frac{\partial^2 L}{\partial x_2 \partial x_m} \right)_{\hat{x}, \hat{\lambda}} \\ \dots & \dots & \dots & \dots \\ \left(\frac{\partial^2 L}{\partial x_m \partial x_1} \right)_{\hat{x}, \hat{\lambda}} & \left(\frac{\partial^2 L}{\partial x_m \partial x_2} \right)_{\hat{x}, \hat{\lambda}} & \dots & \left(\frac{\partial^2 L}{\partial x_m} \right)_{\hat{x}, \hat{\lambda}} \end{bmatrix} \quad (2.12)$$

Funkcja $F_c(\mathbf{x})$ jak i $L(\mathbf{x}, \boldsymbol{\lambda})$ osiągają minimum jeżeli forma kwadratowa (2.9) jest dodatnio określona lub maksimum jeżeli forma kwadratowa (2.9) jest ujemnie określona.

– **uwzględnianie ograniczeń nierównościowych**

W przypadku występowania tylko ograniczeń nierównościowych $h(x)$ zadanie to można rozwiązać również za pomocą tzw. funkcji Lagrange'a o postaci [4, 6, 7, 10, 12, 14, 15, 16]:

$$L(x, \mu) = F_c(x) + \sum_{i=1}^s \mu_i \cdot h_i(x) \quad (2.13)$$

gdzie:

$\mu = (\mu_1, \mu_2, \dots, \mu_s)$ – s -elementowy wektor mnożników Lagrange'a,

$x = (x_1, x_2, \dots, x_m)$ – poszukiwany punkt – optimum, ogólnie rzecz biorąc wektor zmiennych decyzyjnych,

$F_c(x)$ – pierwotna funkcja celu,

$h_i(x) \leq 0$ – ograniczenia nierównościowe, $i = 1, 2, \dots, s$.

Warunkami koniecznymi (zwanymi warunkami Kuhna-Tuckera) istnienia ekstremum, nowo powstałej funkcji celu, są zależności postaci:

$$\begin{cases} \left(\frac{\partial L}{\partial x_k} \right)_{\hat{x}, \hat{\mu}} = 0, & k = 1, \dots, m \\ \left(\frac{\partial L}{\partial \mu_i} \right)_{\hat{x}} \leq 0, & i = 1, \dots, s \\ \hat{\mu}_i \left(\frac{\partial L}{\partial \mu_i} \right)_{\hat{x}} = 0, & i = 1, \dots, s \\ \hat{\mu}_i \geq 0, & i = 1, \dots, s \end{cases} \quad (2.14)$$

gdzie :

$\hat{x}, \hat{\mu}$ – stanowią punkty, w których zarówno funkcja $F_c(x)$ jak i $L(x, \mu)$ osiągają ekstremum warunkowe.


– **uwzględnianie ograniczeń równościowych i nierównościowych jednocześnie**

W przypadku występowania zarówno ograniczeń równościowych $g(x)$ jak i nierównościowych $h(x)$ zadanie to można rozwiązać przy pomocy twierdzenia o punkcie siodłowym funkcji Lagrange'a o postaci [4, 6, 7, 10, 12, 14, 15, 16]:

$$L(x, \lambda, \mu) = F_c(x) + \sum_{i=1}^n \lambda_i \cdot g_i(x) + \sum_{i=1}^s \mu_i \cdot h_i(x) \quad (2.15)$$

Zadanie sprowadza się do znalezienia takiej pary $(\hat{x}, \hat{\lambda})$ (gdzie $\hat{\lambda} = (\hat{\lambda}, \hat{\mu})$) stanowiącej punkt siodłowy Lagrange'a $L(\hat{x}, \hat{\lambda})$, w którym funkcja osiąga minimum względem x i maksimum względem λ przy $\mu > 0$. Zachodzi zatem nierówność:

$$L(\hat{x}, \lambda) \leq L(\hat{x}, \hat{\lambda}) \leq L(x, \hat{\lambda}) \quad (2.16)$$



Rys. 2.1 Interpretacja punktu siodłowego funkcji Lagrange'a [6]

Warunkami koniecznymi (zwanymi warunkami Kuhna-Tuckera) istnienia ekstremum nowopowstałej funkcji celu są zależności o postaci:

względem x

$$\left\{ \begin{array}{ll} \left(\frac{\partial L}{\partial x_k} \right)_{\hat{x}, \hat{\lambda}, \hat{\mu}} \geq 0, & k = 1, \dots, m' \\ \hat{x}_k \left(\frac{\partial L}{\partial x_k} \right)_{\hat{x}, \hat{\lambda}, \hat{\mu}} = 0, & k = 1, \dots, m \\ \left(\frac{\partial L}{\partial x_k} \right)_{\hat{x}, \hat{\lambda}, \hat{\mu}} = 0, & k = m' + 1, \dots, m \\ \hat{x}_k \geq 0, \quad k = 1, \dots, m', \hat{x}_k - \text{o dowolnym znaku}, k = m' + 1, \dots, m \end{array} \right. \quad (2.17)$$

względem $\mathcal{A}$

$$\left\{ \begin{array}{ll} \left(\frac{\partial L}{\partial \lambda_i} \right)_{\hat{x}} = 0, & i = 1, \dots, s \\ \left(\frac{\partial L}{\partial \mu_i} \right)_{\hat{x}} \leq 0, & i = 1, \dots, s \\ \hat{\mu}_i \left(\frac{\partial L}{\partial \mu_i} \right)_{\hat{x}} = 0, & i = 1, \dots, s \\ \hat{\lambda}_i - \text{o dowolnym znaku}, & i = 1, \dots, s \\ \hat{\mu}_i \geq 0, & i = 1, \dots, s \end{array} \right. \quad (2.18)$$

Warunki dostateczne istnienia ekstremum funkcji wynikają z twierdzenie Kuhna-Tuckera. Jeżeli para $(\hat{x}, \hat{\mathcal{A}})$ spełnia warunki konieczne istnienia ekstremum oraz funkcja $F_c(x)$ jest wypukła w dół natomiast funkcje:

- $g_i(x)$ dla $i = 1, \dots, n$, gdy $\hat{\lambda}_i \neq 0$ są liniowe,
- $h_i(x)$ dla $i = 1, \dots, s$, gdy $\hat{\mu}_i > 0$ są wypukłe w dół,

to punkt $\hat{x}$ jest szukanym rozwiązaniem (optimum).

Zastosowanie twierdzenia Kuhna-Tuckera do rozwiązywania zadań optymalizacji z ograniczeniami staje się skomplikowane i nieskuteczne przy dużej liczbie zmiennych (tak jak ma to miejsce w przypadku rozległego systemu elektroenergetycznego). Dlatego też opracowano szereg innych metod, bardziej przydatnych z praktycznego punktu widzenia. Należy do nich zaliczyć [7]:

1. Transformacja zmiennych niezależnych. Ten sposób polega na zamianie problemu z ograniczeniami na problem bez ograniczeń poprzez „transformacje zmiennych niezależnych”, ale w taki sposób, aby funkcja celu nie uległa zmianie. Następnie do rozwiązania stosuje się jedną z metod optymalizacji bez ograniczeń, wymienionych poniżej:
 - metody poszukiwania ekstremum w kierunku
 - metoda złotego podziału,
 - metoda interpolacji kwadratowej,
 - metoda interpolacji sześcienniej,
 - metody bezgradientowe poszukiwania ekstremum
 - metoda Hooka i Jeevesa,
 - metoda Rosenbrocka,
 - metoda Simplexu, Neldera i Meada,
 - metoda Gaussa-Seidela,

- metoda Daviesa, Swanna i Campeya,
 - metoda Powella i jej modyfikacje,
 - metoda Zangwilla,
 - metody gradientowe poszukiwania ekstremum
 - metoda Gradientu Prostego,
 - metoda Najszybszego Spadku i jej modyfikacje,
 - metoda Gradientu Sprzężonego,
 - metoda Davidona,
 - metoda Pearsona,
 - metoda Newtona-Raphsona,
2. Metody z zastosowaniem funkcji kary. Ogólnie rzecz biorąc wyróżnić można zewnętrzną, wewnętrzną i mieszaną funkcję kary, których graficzną interpretację przedstawiono na rys. 2.2. Ten sposób polega na modyfikacji funkcji celu przez wprowadzenie do niej kary za przekroczenie ograniczeń. Następnie do rozwiązania stosuje się jedną z metod optymalizacji bez ograniczeń, wymienionych powyżej. W zależności od sposobu wprowadzenia kary można wyróżnić pięć podstawowych metod:
- *Schmita i Foxa* – uwzględniająca kwadratową funkcję kary zarówno dla ograniczeń równościowych jak i nierównościowych,
 - *Rosenbrocka* – zawierająca trzy strefy: dozwoloną oraz dwie strefy graniczne,
 - *Carrolla* – polegająca na generowaniu w obszarze dopuszczalnym ciągu nieograniczonych powierzchni, których kolejne ekstrema, wyznaczone są metodami optymalizacji bez ograniczeń,
 - *SUMT* (ang. *Sequential Unconstrained Minimization*) – gdzie bieżąca wartość funkcji celu uzależniona jest od wartości w poprzednich k iteracjach,
 - *Powella* – polegająca na poszukiwaniu optimum przez ciąg kolejnych minimalizacji bezwarunkowych zmodyfikowanej funkcji celu.
3. Metody z zastosowaniem modyfikacji kierunków. W tej metodzie dokonuje się modyfikacji kierunku poszukiwań w otoczeniu ograniczeń albo przez „odbicie się” od ograniczeń i kontynuowanie obliczeń w obszarze dopuszczalnym, albo przez rzutowanie kierunku gradientu na powierzchnię styczną do ograniczeń.
4. Metoda Complex. Ten sposób polega na utworzeniu „ograniczonego simpleksu”, który następnie w każdym kroku jest modyfikowany do momentu, aż w bliskim otoczeniu optimum odległość pomiędzy jego wierzchołkami będzie mniejsza niż założona liczba ϵ .

Jedną z metod, zastosowanych po raz pierwszy w elektroenergetyce (opracowaną przez wybitnych amerykańskich uczonych, a jednocześnie inżynierów-praktyków Dommel’a i Tinney’a), jest metoda polegająca na

włączeniu do funkcji celu ograniczeń nierównościowych w postaci kary za ich przekroczenie [5]:

$$\hat{F}_c(\mathbf{x}) = F_c(\mathbf{x}) + \sum_{i=1}^s r_i \cdot h_i^2(\mathbf{x}) \quad (2.19)$$

gdzie

r_i – zmienna dwustanowa o odpowiednio dużej wartości, gdy nie jest spełnione ograniczenie nierównościowe i równa zero, gdy ograniczenie jest spełnione.

Nowa funkcja celu zawiera w sobie już ograniczenia nierównościowe, toteż w kolejnym kroku, do rozwiązywania zadania optymalizacyjnego z pozostałymi ograniczeniami tylko równościowymi, można zastosować funkcję Lagrange’a.

$$L(\mathbf{x}, \boldsymbol{\lambda}) = \hat{F}_c(\mathbf{x}) + \sum_{i=1}^n \lambda_i \cdot g_i(\mathbf{x}) \quad (2.20)$$

Prostota (względna) metody Dommel’a i Tinney’a wynikająca z możliwości bezpośredniego, wielokrotnego wykorzystywania algorytmu rozplływowego bywa często okupiona trudnością z doбором współczynnika kary oraz brakiem zbieżności procesu iteracyjnego.

Metodą alternatywną, w stosunku do zaproponowanej wyżej, jest metoda funkcji kary, w której wprowadzoną już uprzednio ideę kary (w postaci stałego współczynnika) zastosowano do całkowitego wyeliminowania z rozwiązywanego zadania ograniczeń równościowych i nierównościowych [6, 7].


$$T(\mathbf{x}, \mathbf{r}) = F_c(\mathbf{x}) + \sum_{i=1}^n r_i \cdot g_i^2(\mathbf{x}) + \sum_{i=1}^s r_i \cdot h_i^2(\mathbf{x}) \quad (2.21)$$

gdzie

r_i, r_j – parametry zwiększające wartość funkcji naruszanych ograniczeń.

Istnieją wewnętrzne (barierowe), zewnętrzne i mieszane funkcje kary (rys. 2.2).

W praktyce, najczęściej wykorzystywana jest zewnętrzna funkcja kary, jako najbardziej uniwersalna spośród trzech wymienionych powyżej. W większość narzędzi komercyjnych, stosowanych w elektroenergetyce do rozwiązywania nieliniowego zadania OPF, dokonywana jest jego linearyzacja. Liniowe zadanie optymalizacji staje się łatwiejsze do rozwiązania, ale obciążone jest błędem wynikającym z przyjęcia założeń upraszczających. Trudności, na które natrafił autor niniejszej monografii podczas wykonywania różnego rodzaju analiz, skłoniły go do poszukiwania nowej metody, alternatywnej w zakresie rozwiązywania zadań OPF a także SCOPF. Celem przyświecającym chęci znalezienia nowego algorytmu, było zwiększenie jego skuteczności oraz zmniejszenie czasu obliczeń.



Rys. 2.2 Przykładowe postacie funkcji kary [6]

2.2.3 Optymalizacja liniowa z ograniczeniami

Zagadnienia optymalizacji liniowej (zwanej też programowaniem liniowym) stanowią szczególny przypadek zadań z ograniczeniami równościowymi i nierównościowymi. Mogą być one przybliżeniem zadań nieliniowych lub tworzyć etapy pomocnicze przy ich rozwiązywaniu. Aby problem został uznany za liniowy zarówno funkcja celu jak i ograniczenia muszą być liniowe.

Funkcja celu przy programowaniu liniowym przyjmuje postać [6]:

$$F_c(\mathbf{x}) = \sum_{i=1}^m c_i \cdot x_i \quad (2.22)$$

Warunki ograniczające mogą być zapisane w postaci:

- standardowej

[illegible]

- klasycznej

[illegible]


- ogólnej

$$\left\{ \begin{array}{l} a_{11} \cdot x_1 + a_{12} \cdot x_2 + \dots + a_{1m} \cdot x_m = b_1 \\ a_{21} \cdot x_1 + a_{22} \cdot x_2 + \dots + a_{2m} \cdot x_m = b_2 \\ \\ a_{n1} \cdot x_1 + a_{n2} \cdot x_2 + \dots + a_{nm} \cdot x_m = b_n \\ \\ a_{11} \cdot x_1 + a_{12} \cdot x_2 + \dots + a_{1m} \cdot x_m \leq b_1 \\ a_{21} \cdot x_1 + a_{22} \cdot x_2 + \dots + a_{2m} \cdot x_m \leq b_2 \\ \\ a_{s1} \cdot x_1 + a_{s2} \cdot x_2 + \dots + a_{sm} \cdot x_m \leq b_s \\ x_i \geq 0, \quad i=1, 2, ..., m', \text{ dowolne } x \text{ dla } i=m'+1, 2, ..., m \end{array} \right. \tag{2.25}$$

Ekstremum funkcji można znaleźć na podstawie znajomości następujących reguł [6]:

- „jeżeli zbiór punktów dopuszczalnych zadania optymalizacji liniowej jest wielościaniem wypukłym ograniczonym, to ekstremum funkcji występuje przynajmniej w jednym z punktów wierzchołkowych wielościanu”,
- „jeżeli zbiór punktów dopuszczalnych zadania optymalizacji liniowej jest wielościaniem wypukłym nieograniczonym oraz funkcja celu jest ograniczona z góry (z dołu), to ekstremum funkcji występuje przynajmniej w jednym z punktów wierzchołkowych tego zbioru. Jeżeli wartość maksymalna (minimalna) funkcji celu jest skończona to wartość minimalna (maksymalna) może być nieograniczona”.

Na poniższym rysunku przedstawiono przykład graficznej interpretacji zadania optymalizacji liniowej z ograniczeniami (Φ – zbiór punktów dopuszczalnych).



Rys. 2.3 Graficzna interpretacja zadania optymalizacji liniowej z ograniczeniami [4, 6]

Najbardziej znaną metodą rozwiązywania zagadnień optymalizacji liniowej jest metoda Simpleks [2, 3, 4, 6, 7, 12, 13, 15, 16].

Jeżeli zadanie programowania liniowego zapiszemy w postaci standardowej:

$$\min[F_c(\mathbf{x})] = \min\left(\sum_{i=1}^m c_i \cdot x_i\right) \quad \text{przy ograniczeniach} \quad (2.26)$$

$$A \cdot x = b$$

$$\mathbf{x} \geq \mathbf{0}$$

wówczas jego rozwiązanie metodą simpleks będzie polegało na znalezieniu odpowiedniego wierzchołka wielościanu ograniczonego.

W tym celu należy zadanie zapisać w postaci kanonicznej:

[illegible]

W postaci macierzowej, powyższe równanie przyjmie postać:

$$\begin{bmatrix} \mathbf{B} & \mathbf{N} \end{bmatrix} \cdot \begin{bmatrix} \mathbf{x}_B \\ \mathbf{x}_N \end{bmatrix} = \mathbf{b} \quad (2.28)$$

$$\mathbf{x} \geq \mathbf{0}$$

gdzie:

$\mathbf{x}_B$ – wektor zmiennych bazowych,

$\mathbf{x}_N$ – wektor zmiennych niebazowych,

dla $\mathbf{x}_N = \mathbf{0}$, rozwiązanie zadania nazywa się rozwiązaniem bazowym:

$$\mathbf{x}_B = \mathbf{B}^{-1} \cdot \mathbf{b} \quad (2.29)$$

W kolejnym kroku należy funkcję celu przekształcić do postaci:

$$F_c(\mathbf{x}) = \mathbf{c}^T \cdot \mathbf{x} = \mathbf{c}_B^T \cdot \mathbf{x}_B + \mathbf{c}_N^T \cdot \mathbf{x}_N,$$

$$\mathbf{c} = \begin{bmatrix} \mathbf{c}_B \\ \mathbf{c}_N \end{bmatrix} \quad (2.30)$$

Na podstawie równania 2.28 można zapisać:

$$\mathbf{B} \cdot \mathbf{x}_B + \mathbf{N} \cdot \mathbf{x}_N = \mathbf{b} \quad (2.31)$$

$$\mathbf{x}_B = \mathbf{B}^{-1} \cdot \mathbf{b} - \mathbf{B}^{-1} \cdot \mathbf{N} \cdot \mathbf{x}_N$$

Wstawiając zależność na $\mathbf{x}_B$ do wzoru na funkcję celu otrzymamy:

$$F_c(\mathbf{x}) = \mathbf{q}_0 + \mathbf{p}^T \cdot \mathbf{x}_N,$$

gdzie :

$$\mathbf{q}_0 = \mathbf{c}_B^T \cdot \mathbf{B}^{-1} \cdot \mathbf{b} \quad (2.32)$$

$$\mathbf{p}^T = \mathbf{c}_N^T - \mathbf{c}_B^T \cdot \mathbf{B}^{-1} \cdot \mathbf{N}$$

O tym, czy dane rozwiązanie jest optymalne decyduje kryterium optymalności, które polega na wyznaczeniu wektora $\mathbf{p}$. Wyróżnić można trzy przypadki:

- wszystkie składowe wektora $\mathbf{p}$ są dodatnie, co oznacza, że rozwiązaniem optymalnym jest $\hat{\mathbf{x}} = \mathbf{x}_B$,
- wszystkie składowe wektora $\mathbf{p}$ są równe zero, co oznacza że rozwiązanie jest niejednoznaczne (istnieją inne punkty, w których funkcja celu nie zmieni wartości),
- wektor $\mathbf{p}$ posiada składową ujemną/składowe ujemne (należy wybrać najmniejszą z nich). W tym przypadku istnieją inne punkty, w których funkcja przyjmuje lepsze wartości.

Generalnie rzecz biorąc, szukanie optimum polega na uporządkowanym poruszaniu się po wierzchołkach zbioru dopuszczalnego. Kolejne punkty, generowane w trakcie procesu optymalizacyjnego, charakteryzują się tym, że wartość funkcji celu nie ulega pogorszeniu. Zastosowanie optymalizacji liniowej w elektroenergetyce jest możliwe po linearyzacji modelu SEE (metoda stałoprądowa).

Po przyjęciu typowych dla metody stałoprądowej założeń upraszczających: napięcia równe napięciom znamionowym, pominięcie rezystancji elementów i operowanie wyłącznie reaktancją, zastąpienie funkcji trygonometrycznych (*sinus* i *cosinus*) różnicą kątów fazorów napięcia w węzłach sąsiednich, równanie na moc czynną i prąd w gałęzi można zapisać w postaci [171]:

$$\mathbf{P} = U_n^2 \cdot \mathbf{Y} \cdot \boldsymbol{\delta} \quad (2.33)$$

gdzie:

$\mathbf{P}$ – macierz kolumnowa mocy czynnych,

$\mathbf{Y}$ – macierz admitancyjna węzłowa sieci,

$\boldsymbol{\delta}$ – macierz kolumnowa kątów napięć.

Moc bierna wyznaczana jest w oparciu o wyniki uzyskane z obliczeń mocy czynnej.

Równanie na prąd w gałęzi można zapisać w postaci [171]:

$$I_{ij} = \mathbf{c}^T \cdot \mathbf{P} \quad (2.34)$$

gdzie współczynnik c określający udział źródła/odbioru przyłączonego do węzła k w obciążaniu się linii ij , wyraża się wzorem [171]:

$$c_{(ij)k} = \frac{1}{U_n} \cdot \frac{(\hat{Z}_{ki} - \hat{Z}_{kj})}{X_{ij}} \quad (2.35)$$

Po zmianie struktury sieci (wyłączeniu gałęzi przyłączonej do węzłów k oraz l), współczynniki macierzy impedancyjnej, w nowym stanie, można wyznaczać ze wzoru:

$$\hat{Z}_{ij}^{\text{new}} = \hat{Z}_{ij}^{\text{old}} - \frac{(\hat{Z}_{ik} - \hat{Z}_{il}) \cdot (\hat{Z}_{kj} - \hat{Z}_{lj})}{\hat{Z}_{kk} + \hat{Z}_{ll} - 2 \cdot \hat{Z}_{kl} - \hat{Z}_{k-l}} \quad (2.36)$$

gdzie:

$\hat{Z}_{ij}^{\text{old}}$, $\hat{Z}_{ij}^{\text{new}}$ – elementy macierzy impedancyjnej przed i po wyłączeniu gałęzi łączącej węzły k oraz l ,

$\hat{Z}_{k-l}$ – impedancja gałęzi łączącej węzły k oraz l .

Biorąc powyższe pod uwagę, zadania typu OPF i SCOPF dają się wówczas rozwiązać metodą simpleks [6, 7, 12, 13, 170, 171].

2.2.4 Optymalizacja kombinatoryczna z ograniczeniami

We wcześniejszych rozdziałach omówiono przykłady metod optymalizacji ciągłej. W przypadku zmiennych dyskretnych mamy do czynienia z optymalizacją kombinatoryczną (dyskretną). Niektóre zagadnienia w elektroenergetyce charakteryzują się występowaniem zmiennych dyskretnych. Rozważając zagadnienia liniowe, można je podzielić na dwa zadania programowania zero-jedynkowego i całkowitoliczbowego [4].

1. Zadanie programowania zero-jedynkowego

Zadanie to można zapisać w postaci:

$$\min [F_c(\mathbf{x})] = \min \left(\sum_{i=1}^m c_i \cdot x_i \right)$$

przy ograniczeniach

$$\mathbf{A} \cdot \mathbf{x} \leq \mathbf{b}$$
$$x_i = 0 \text{ lub } x_i = 1$$
(2.37)

Liczba zmiennych wynosi m . Każda zmienna może przyjmować dwie wartości: 0 lub 1, także liczba możliwych rozwiązań wynosi 2^n . Zadanie to można rozwiązać poprzez przegląd:

1. bezpośredni (jawny), polegający na przeszukaniu wszystkich rozwiązań i znalezieniu optymalnego,
2. pośredni (niejawny), polegający na wykorzystaniu filtrów, pozwalających odrzucić niektóre rozwiązania bez ich wcześniejszego sprawdzenia.

Algorytmy pozwalające rozwiązać to zadanie podane są m. in. w [172, 173, 174, 175]. Na uwagę zasługuje algorytm opracowany przez Balasa, zwany zero-jedynkowym addytywnym algorytmem Balasa. Opiera się on na trzech testach:

- I – mający na celu stwierdzenie czy można polepszyć wartość funkcji celu
i zmniejszyć stopień niedopuszczalności ograniczenia,
- II – niedopuszczalności,
- III – test rozgałęzień Balasa.

W powyższym algorytmie rozpatruje się 2^n – elementowy zbiór możliwych rozwiązań próbnych. Następnie, tworząc kolejne rozwiązania próbne (poprzez nadawanie zmiennym wartości 0 lub 1), bada się czy są spełnione ograniczenia. W kolejnych iteracjach otrzymuje się częściowe rozwiązania dopuszczalne, dla których pewna liczba zmiennych ma wartości ustalone, a pozostałe są dopełnieniem częściowych rozwiązań z ustalonymi zmiennymi.

2. Zadanie programowania całkowitoliczbowego

Zadanie to można zapisać w postaci:

$$\min [F_c(\mathbf{x})] = \min \left(\sum_{i=1}^m c_i \cdot x_i \right)$$

przy ograniczeniach

$$\mathbf{A} \cdot \mathbf{x} \leq \mathbf{b}$$
$$x_i \geq 0, \quad x_i \in C \quad (C - \text{zbiór liczb całkowitych})$$
(2.38)

Zadanie to można rozwiązać poprzez zastosowanie:

1. systematycznego przeszukiwania dopuszczalnego obszaru i sprawdzania funkcji celu w każdym punkcie,
2. zastąpienia zadaniem programowania zero-jedynkowego,
3. algorytmu sympleks i zaokrąglenie uzyskanego rozwiązania,
4. algorytmu odcięć podstawowych Gomory'ego, który wymaga rozwiązywania zadania programowania liniowego po każdym odcięciu,
5. techniki płaszczyzn odcinających,
6. algorytmu odcięć podstawowych dla niepełnego zadania całkowitoliczbowego,
7. algorytmów dekompozycji.

W przypadku zagadnień nieliniowych stosuje się metody optymalizacji opisane w rozdziale 2.2.2 lub 2.3 i 3 pamiętając o tym, że zbiór zmiennych decyzyjnych jest skończony i dyskretny.

2.3 Optymalizacja heurystyczna

2.3.1 Algorytmy

Heurystyką (grec. *heuresis* – odnaleźć, odkryć, *heureka* – znalazłem) nazywa się sztukę rozwiązywania różnego rodzaju zadań, które nie mogą być rozwiązane metodami klasycznymi lub zastosowanie tych metod jest zbyt czasochłonne i pracochłonne.

Heurystyka to ogólnie strategia, polegająca na sterowaniu procesem wyszukiwania. Jej celem jest sprawne eksplorowanie przestrzeni poszukiwań w celu znalezienia rozwiązań niemal optymalnych. Techniki, które stanowią heurystyczne algorytmy, bazują zarówno na prostych procedurach wyszukiwania lokalnego, jak i złożonych procesach uczenia się. Cechuje je to, że są przybliżone i zazwyczaj niedeterministyczne.

Zgodnie z teorią No-Free-Lunch [230] nie ma algorytmu, który pozwalałby rozwiązać wszystkie problemy optymalizacji. Oznacza to, że w danej klasie problemów niektóre algorytmy radzą sobie lepiej, podczas gdy w innym zestawie zadań są mniej efektywne. Dlatego też warto szukać nowych metod, za pomocą których można rozwiązywać rzeczywiste problemy należące do danej klasy, lepiej niż stosując istniejące algorytmy.

W literaturze opisanych zostało wiele heurystycznych metod optymalizacyjnych, dla których inspiracją była obserwacja zjawisk przyrodniczych, fizycznych czy nawet socjologicznych. Niektóre z nich są mało popularne (rzadko stosowane) lub wtórne do już istniejących. Wyróżnić można następujące rodzaje metod:

1. Sztuczne sieci neuronowe (ang. *artificial neural network*) [53, 54].
2. Systemy rozmyte (ang. *fuzzy systems*) [57, 58].
3. Algorytmy ewolucyjne (ang. *evolutionary algorithms*) [55, 56, 21, 36].

4. Symulowane wyżarzanie (ang. *simulated annealing*) [59].
5. Sztuczne systemy immunologiczne (ang. *artificial immune systems*) [60, 61, 62].
6. Optymalizacja rojem cząstek (ang. *particle swarm optimization*) [63, 64].
7. Algorytmy mrówkowe (ang. *ant algorithms*) [65, 66].
8. Algorytmy pszczele (ang. *bees algorithms*) [67, 68].
9. Sztuczna kolonia pszczół (ang. *artificial bee colony*) [123].
10. Algorytmy poszukiwania harmonii (ang. *harmony search*) [69, 70].
11. Algorytmy kulturowe (ang. *cultural algorithms*) [71, 72].
12. Algorytmy memetyczne (ang. *memetic algorithm*) [73, 74, 75].
13. Algorytmy bakteryjne (ang. *bacterial algorithms*) [76].
14. Algorytmy świetlikowe (ang. *firefly algorithm*) [77].
15. Algorytm nietoperzy (ang. *bat algorithm*) [79].
16. Przeszukiwanie z tabu (ang. *tabu search*) [80, 81, 82].
17. Przeszukiwanie kukułczane (ang. *cuckoo search*) [78, 83].
18. Strategia orła (ang. *eagle strategy*) [84].
19. Algorytmy fotosyntetyczne i enzymatyczne (ang. *photosynthetic and enzyme algorithms*) [78].
20. Dynamika formowania rzeki (ang. *river formation dynamics*) [85].
21. Algorytmy karaluchowe (ang. *roach infestation optimisation*) [86].
22. Algorytmy komarze (ang. *mosquito host-seeking*) [87].
23. Algorytm optymalizacji śluzowcami (ang. *slime mould life cycle*) [88].
24. Inteligentne krople wody (ang. *intelligent water drops*) [89].
25. Algorytm żabich skoków (ang. *shuffled frog leaping algorithm*) [90].
26. Algorytm kolonizacji chwastów (ang. *weed colonization optimization*) [91].
27. Algorytm ekosystemowy [50].
28. Algorytm biogeograficzny (ang. *biogeography-based optimization*) [92].
29. Algorytm optymalizacji spiralnej (ang. *spiral optimization algorithm*) [93, 94].
30. Algorytm cyklu hydrologicznego (ang. *hydrological cycle algorithm*) [95].
31. Algorytm grawitacyjny (ang. *gravitational search algorithm*) [96].
32. Algorytm zapylania kwiatów (ang. *flower pollination algorithm*) [97].
33. Algorytm optymalizacji mątwy (ang. *cuttlefish optimization algorithm*) [98, 99].
34. Algorytm orki zabójcy (ang. *killer whale algorithm*) [100].
35. Algorytm wody deszczowej (ang. *rain water algorithm*) [101].
36. Algorytm optymalizacji ćmy (ang. *moth-flame optimization algorithm*) [102].
37. Algorytm optymalizacji poszukiwacza (ang. *seeker optimization algorithm*) [103].
38. Algorytm optymalizacji raf koralowych (ang. *a novel coral reefs optimization algorithm*) [104].
39. Algorytm zawodów w piłce nożnej (ang. *soccer league competition algorithm*) [105].
40. Algorytm przeszukiwania symbiotycznego (ang. *symbiotic organisms search*) [106].

41. Algorytm wybuchu miny (ang. *mine blast algorithm*) [107].
42. Algorytm czarnej dziury (ang. *black hole algorithm*) [109].
43. Algorytm optymalizacji promienia (ang. *ray optimization algorithms*) [110].
44. Algorytm przeszukiwania ładunku (ang. *charged system search*) [111].
45. Algorytm optymalizacji reakcji chemicznej (ang. *chemical-reaction-inspired metaheuristic for optimization*) [112].
46. Algorytm optymalizacji chemicznej (ang. *chemistry based metaheuristic optimization method*) [113].
47. Algorytm przeszukiwania myśliwskiego (ang. *hunting search algorithm*) [114].
48. Algorytm echolokacji delfinów (ang. *dolphin echolocation*) [115].
49. Algorytm optymalizacji szarego wilka (ang. *grey wolf optimizer*) [116].
50. Algorytm muszki owocowej (ang. *fruit fly optimization algorithm*) [117].
51. Algorytm optymalizacji cząstek gazu (ang. *gases Brownian motion optimization algorithm*) [118].
52. Algorytm optymalizacji stanu materii (ang. *states of matter optimization algorithm*) [119].
53. Algorytm optymalizacji negatywnych skutków sztucznego oświetlenia (ang. *the ecological impacts of nighttime light pollution algorithm*) [120].
54. Algorytm chaotycznego stada krylu (ang. *chaotic krill herd algorithm*) [121].
55. Optymalizacja rojem światełków (ang. *glowworm swarm optimisation*) [122].
56. Imperialistyczny algorytm konkurencyjny (ang. *imperialist competitive algorithm*) [124, 125].
57. Inteligencja sztucznego roju (ang. *artificial swarm intelligence*) [126].
58. Algorytm pojedynku (ang. *duelist algorithm*) [127].
59. Ewolucyjny algorytm membranowy (ang. *evolutionary membrane algorithm*) [128].
60. Ludzki algorytm ewolucyjny (ang. *human evolutionary model*) [129].
61. Algorytm optymalizacji rozmnażania bezpłciowego (ang. *asexual reproduction optimization*) [130].
62. Optymalizacja typu nauczanie-uczenie (ang. *teaching-learning-based optimization*) [205, 206, 207].
63. Algorytm optymalizacji oparty o zachowania społeczne (ang. *society and civilization*) [208].
64. Losowe sieci ewolucyjne (ang. *genetic evolutionary random weight networks*) [225].
65. Optymalizacja pasikonika (ang. *grasshopper optimization approaches*) [226].
66. Algorytm optymalizacji roju ryb (ang. *salp swarm algorithm*) [228, 228].
67. Chaotyczny cykl wody (ang. *chaotic water cycle*) [229].

Nieustannie rozwijane i tworzone są nowe algorytmy, pozwalające uzyskiwać coraz lepsze wyniki [231, 232, 233, 234, 235, 236, 237, 238, 239, 240, 241, 242].

Oprócz wymienionych algorytmów są jeszcze inne, mniej lub bardziej popularne. Część z nich, tak jak już wspomniano, powstaje na podstawie już istniejących, poprzez zmianę odpowiednich założeń odnośnie parametrów sterujących.

Podsumowując wszystkie wymienione powyżej algorytmy, można powiedzieć, że jest to klasa metod przeznaczonych do rozwiązywania problemów trudnych, nietypowych, złożonych, wielowymiarowych, dyskretnych, nie do końca precyzyjnie określonych. Cechy tych algorytmów, takie jak, pełna losowość, obliczenia na n -wektorach zmiennych jednocześnie, możliwość modyfikacji w trakcie trwania obliczeń powodują, że stają się one coraz bardziej popularne. Często sięga się po nie w praktyce, gdy zastosowanie metod klasycznych jest trudne lub wręcz niemożliwe lub też konieczne jest szybkie rozpoznanie problemu. Należy sobie zdawać jednocześnie sprawę z tego, że nie gwarantują one zawsze, w stu procentach, precyzyjnego znalezienia optimum globalnego. Umożliwiają jednak określenie obszaru, w którym ono się znajduje lub błądzenie w jego pobliżu. Jest to szczególnie przydatne w sytuacjach braku możliwości zastosowania innych algorytmów.

Autor niniejszej monografii w swoich badaniach wykorzystywał kilka metod heurystycznych wymienionych poniżej:

- algorytmy genetyczne (GA),
- symulowane wyżarzanie (SA),
- rój cząstek (PSO),
- przeszukiwanie kukułczane (CS),
- algorytm optymalizacji ćmy (MFO),
- algorytm optymalizacji szarego wilka (GWO).

Doświadczenia z nimi związane, zainspirowały autora do poszukiwań nowej metody optymalizacji heurystycznej. Jest nią metoda AIG (ang. *Algorithm of Innovative Gunner* – **AIG**), zwana również metodą balistyczną, opisana w rozdziale 3. Jej wysoka skuteczność oraz praktyczna przydatność udowodniona została w rozdziałach 3–14.

2.3.2 Sposoby uwzględniania ograniczeń

Niezwykle ważnym zagadnieniem w optymalizacji jest sposób uwzględniania ograniczeń. Stosowane są różne metody, opisane poniżej. Ogólnie rzecz biorąc uwzględnianie ograniczeń dzieli się na kategorie [21, 22]:

Kategoria 1: Metody oparte na funkcjach kary

Większość sposobów bazuje na metodach związanych z funkcją kary oraz metodach barierowych [2, 3, 4, 5, 6, 7, 10, 12, 16]. Jak już wspomniano w punkcie 2.2.2, ogólnie wyróżnić można metody funkcji kary wewnętrznej, zewnętrznej i mieszanej.

Obliczenia z pomocą funkcji kary przebiegają według ogólnej zależności:

$$\begin{cases} \hat{F}_c(\mathbf{x}) = F_c(\mathbf{x}) & \text{jeżeli } \mathbf{x} \text{ należy do obszaru dopuszczalnego} \\ \hat{F}_c(\mathbf{x}) = F_c(\mathbf{x}) + P(\mathbf{x}) & \text{w innym przypadku} \end{cases} \quad (2.39)$$

gdzie:

$F_c(\mathbf{x})$ – pierwotna funkcja celu,

$P(\mathbf{x})$ – funkcja kary,

$\hat{F}_c(\mathbf{x})$ – nowa funkcja celu z karą.

Inny podział metod to:

- *kary śmierci* [23, 21], polegająca na odrzucaniu rozwiązań, które leżą w obszarze niedopuszczalnym. Należy pamiętać o tym, aby startować z obszaru dopuszczalnego.
- *statycznych kar* [24, 25], polegająca na tworzeniu przedziałów dla określonych ograniczeń. Kara uwzględniana jest według zależności:

$$\hat{F}_c(\mathbf{x}) = F_c(\mathbf{x}) + \sum_{i=1}^s r_{ij} \cdot P_i^2(\mathbf{x}) \quad (2.40)$$

gdzie:

r_{ij} – jest parametrem kary dla każdego naruszenia j i dla każdego ograniczenia i ,

- *dynamicznych kar* [26, 27], polegająca na ocenianiu aktualnych rozwiązań za pomocą odpowiedniej, dynamicznie zmieniającej się zależności:

$$\hat{F}_c(\mathbf{x}) = F_c(\mathbf{x}) + (c \cdot t)^\alpha \cdot \sum_{j=1}^s P_j^\beta(\mathbf{x}) \quad (2.41)$$

gdzie:

c, α i β są stałymi, a t jest kolejną iteracją,

- *kar wyżarzanych* [28, 29], w której współczynniki kary zmieniają funkcje celu w sposób następujący:

$$\hat{F}_c(\mathbf{x}) = F_c(\mathbf{x}) + \frac{1}{2 \cdot t} \cdot \sum_{j=1}^m P_j^2(\mathbf{x}) \quad (2.42)$$

gdzie:

t – kolejna iteracja,

- *kar adaptacyjnych* [30, 31, 32, 33], polegająca na korygowaniu kar poprzez informację o poprzednim rozwiązaniu:

$$\hat{F}_c(\mathbf{x}) = F_c(\mathbf{x}) + \lambda(t) \cdot \sum_{j=1}^s P_j^2(\mathbf{x}) \quad (2.43)$$

gdzie:

$\lambda(t)$ jest funkcją, która zależy od kolejnej iteracji;

- *segregacji* [34], polegająca na kontrolowaniu liczby rozwiązań leżących w obszarze dopuszczalnym i niedopuszczalnym.
- *kar ewolucyjnych* [35], gdzie współczynniki kary „ewoluują” w każdej iteracji.

Obliczenia z pomocą metod barierowych przebiegają według ogólnej zależności:

$$\hat{F}_c(\mathbf{x}) = F_c(\mathbf{x}) + r \cdot \sum_{i=1}^s \frac{-1}{h_i(\mathbf{x})} \quad (2.44)$$

gdzie:

r – jest parametrem barierowym,

$F_c(\mathbf{x})$ – pierwotna funkcja celu,

$\hat{F}_c(\mathbf{x})$ – nowa barierowa funkcja celu.

Kategoria 2: Metody oparte na poszukiwaniu dopuszczalnych rozwiązań

Wyróżnić można następujące rodzaje metod:

- poprawy niedopuszczalnych punktów [37], polegająca na ich modyfikacji poprzez korzystanie z mechanizmów, np. koewolucyjnych. Korzysta się tutaj z wiedzy na temat rodzaju i struktury ograniczeń, aby dostosować sposób poprawy zmiennych w celu „wciągnięcia” ich w obszar dopuszczalny.
- przewagi dopuszczalnych punktów [38, 39]. Jedno z ciekawszych podejść bazuje na stwierdzeniu, że każde rozwiązanie dopuszczalne jest lepsze od dowolnego rozwiązania niedopuszczalnego. Można to zapisać w postaci zależności:


$$\hat{F}_c(\mathbf{x}) = \begin{cases} F_c(\mathbf{x}) & \text{dla } \mathbf{x} \in D \\ F_{\text{cmax}}(\mathbf{x}) + \sum_{j=1}^s P_j(\mathbf{x}) & \text{dla } \mathbf{x} \notin D \end{cases} \quad (2.45)$$

gdzie:

D – jest obszarem dopuszczalnym

$F_{\text{CMAX}}(x)$ – jest maksymalną („najgorszą”) wartością funkcji celu w obszarze dopuszczalnym.

Interpretacja graficzna tej metody została przedstawiona na rys. 2.4.



Rys. 2.4 Graficzna interpretacja metody rozgraniczającej rozwiązania dopuszczalne od niedopuszczalnych

- uwzględniania ograniczeń według określonej kolejności (metoda pamięci behawioralnej) [40]. Wymaga ona ustalenia kolejności rozpatrywania wszystkich ograniczeń. Kolejność ta, wpływa oczywiście na efekty końcowe obliczeń, ale jej wpływ na wynik nie jest do końca znany.

Kategoria 3: Metody oparte na zachowywaniu dopuszczalnych rozwiązań

Wyróżnić można następujące sposoby:

- stosowanie specjalnych operatorów (system GENOCOP [41]).
- przeszukiwanie granic dopuszczalnego obszaru [43].
- mapowanie homomorficzne [43].

Kategoria 4: Metody oparte na dekodernach [42, 176], charakteryzujące się tym, że dają zawsze dopuszczalne rozwiązanie.

Kategoria 5: Metody hybrydowe [44, 45, 46, 47, 48], które łączą w sobie różne metody.

3. Nowa autorska metoda optymalizacji heurystycznej – Algorytm Innowacyjnego Artylerzysty (ang. *Algorithm of the Innovative Gunner – AIG*)

3.1 Uwagi wstępne

W niniejszym rozdziale przedstawiono nową metodę optymalizacji heurystycznej, dla której inspiracją jest taki dobór parametrów działu artyleryjskiego, by kolejny wykonany strzał precyzyjnie osiągnął cel. Zastosowana korekta parametrów ustawienia działu jest jednak inna niż określa to klasyczna teoria artylerii. Stąd w nazwie metody sformułowanie „innowacyjny...” odnoszące się do artylerzysty. Innowacyjność algorytmu wynika z faktu zastosowania, w każdym kroku procesu iteracyjnego, korekty poprzedniego rozwiązania za pomocą specjalnie dobranych mnożników. Stanowi to zasadniczą różnicę w stosunku do większości metod, w których w kolejnym kroku element korygujący jest dodawany do poprzedniego rozwiązania. Zaprezentowany algorytm (ang. AIG) charakteryzuje się wysoką skutecznością i szybkością w rozwiązywaniu różnych zadań optymalizacyjnych, niemających nic wspólnego z balistyką i artylerią. Jest on przy tym niezwykle prosty w opisie i implementacji. Algorytm został przetestowany na znanych, testowych zagadnieniach optymalizacyjnych. Uzyskane wyniki są zauważalnie lepsze od osiągniętych innymi metodami i udowadniają praktyczną przydatność algorytmu AIG (rozdział ten zawiera rozszerzony opis algorytmu opublikowanego w czasopiśmie *Engineering Optimization* [166]).

Poszukiwanie nowych metod inteligencji obliczeniowej pozwala zwiększać skuteczność rozwiązywania szczególnie trudnych i nietypowych zadań obliczeniowych i problemów, dla których zastosowanie metod klasycznych [1, 2, 3, 4, 5, 6, 7, 8, 9, 10, 11, 12, 13, 14, 15, 16, 17, 19, 20] zawodzi. Proponowana metoda pośrednio bazuje na zjawiskach przyrodniczych, takich jak grawitacja, opór powietrza czy prędkość i kierunek wiatru. Bezpośrednio natomiast dotyczy skuteczności namierzania celu i wstępnego korygowania lotu pocisku (pocisków) za pomocą odpowiedniego ustawienia broni (działa).

Konfrontując tę metodę z algorytmami już istniejącymi należy podkreślić, że prezentowane podejście nie było jeszcze dotychczas rozważane i analizowane. W związku z tym autor uważa je za własne oryginalne osiągnięcie naukowe.

Biorąc powyższe pod uwagę można postawić następującą tezę:


Algorytmy heurystyczne, w tym autorski algorytm AIG, mogą być efektywnie wykorzystywane do rozwiązywania zadań optymalizacji w elektroenergetyce, ponieważ pozwalają skutecznie minimalizować funkcje celu z dyskretnymi i ciągłymi zmiennymi decyzyjnymi przy różnych ograniczeniach funkcyjnych (liniowych i nieliniowych oraz równościowych i nierównościowych).

Teza zostanie udowodniona w rozdziałach 3–14 poprzez:

- wykonanie testów obliczeniowych nowego algorytmu. Testy będą obejmowały różne funkcje celu z różnych dziedzin naukowych,
- odpowiedni dobór i analizę wybranych zagadnień optymalizacyjnych w elektroenergetyce,
- porównanie wyników obliczeń z wynikami uzyskanymi za pomocą innych algorytmów, uznawanych za klasykę heurystyki.

3.2 Inspiracja

Zadaniem jest strzelić z działa pod takim kątem, aby przy losowych zakłóceniach trafić w cel.



Rys. 3.1 Inspiracja algorytmu AIG

Chociaż jak wspomniano wcześniej, inspiracją dla większości metod heurystycznych jest natura, to w przypadku prezentowanego algorytmu AIG zwanego też „balistycznym” inspiracją był pewien pomysł matematyczny, dla którego z czasem określono interpretację bazującą na teorii rzutu ukośnego będącą podstawą balistyki. Rozpatrując zadanie optymalizacyjne, w którym funkcja celu F_c jest funkcją wektora zmiennych decyzyjnych

$$[x] = [x_1, \dots, x_l, \dots, x_n] \quad (3.1)$$

Poszukuje się takich wartości tych zmiennych, które zapewnią minimalną wartość funkcji celu, tj.

$$F_c(x) = F_c(x_1^s, \dots, x_l^s, \dots, x_n^s) \rightarrow \min \quad (3.2)$$

Nawet wobec niezwykle dużej liczby metod, które zapewniają rozwiązanie tego zadania, można stwierdzić, że proces iteracyjny określania optymalnych wartości składowych wektora $[x]$ jest podobny, albowiem najczęściej w kolejnym kroku iteracyjnym wykonywane jest działanie

$$x_l^{(i+1)} = x_l^{(i)} + \Delta x_l^{(i)} \quad (3.3)$$

zaś korekta składowej l -tej wektora, w i -tym kroku iteracyjnym, wyznaczana jest jako wartość funkcji

$$\Delta x_l^{(i)} = f_l(\xi) \quad (3.4)$$

Należy zauważyć, że zarówno postać funkcji f_i , jak i też składowe wektora ξ to symboliczny zapis i cecha charakterystyczna zastosowanej metody heurystycznej, jednej z wielu wskazanych wyżej.

W oparciu o powyższą zależność, obliczenia wykonywane są np. w metodach:

- roju cząstek (PSO),

$$\mathbf{x}_{k+1}^i = \mathbf{x}_k^i + \mathbf{v}_{k+1}^i \quad (3.5)$$

$$\mathbf{v}_{k+1}^i = w \cdot \mathbf{v}_k^i + c_1 \cdot r_1 \cdot (\mathbf{p}^i - \mathbf{x}_k^i) + c_2 \cdot r_2 \cdot (\mathbf{p}^g - \mathbf{x}_k^i) \quad (3.6)$$

gdzie:

$\mathbf{x}_k^i$ – jest wektorem położenia i -tej cząstki w k -tej iteracji,

$\mathbf{v}_k^i$ – jest wektorem prędkości i -tej cząstki w k -tej iteracji,

$\mathbf{p}^i$ – jest najlepszym, dotychczas znalezionym położeniem i -tej cząstki,

$\mathbf{p}^g$ – jest najlepszym położeniem znalezionym przez lidera roju,

w – jest współczynnikiem bezwładności ruchu cząstki,

c_1, c_2 – są to ustalone współczynniki przyspieszenia lub uczenia się,

r_1, r_2 – są liczbami uzyskiwanymi z generatora liczb losowych o rozkładzie równomiernym w przedziale $[0,1]$.

Wzór (3.5) może budzić wątpliwość, ponieważ do położenia dodawana jest prędkość. Należy jednak zauważyć, że aktualizacja położenia każdej cząstki dokonywana jest po jednej iteracji algorytmu, więc jest on prawdziwy dla $t = 1$ s. Dlatego w literaturze spotyka się taką jego postać.

- algorytmu ekosystemowego,
- algorytmu nietoperzy,
- algorytmu grawitacyjnego,
- algorytmu optymalizacji spiralnej, itp.

W niektórych algorytmach, nowe rozwiązanie znajdowane jest w oparciu o sumę poprzedniego i losowo wyznaczanego kroku (odbywa się to poprzez losowanie nowego punktu w otoczeniu bieżącego), który określany jest według ogólnej zasady:

$$x_l^{(i+1)} = x_l^{(i)} + \omega_l^{(i)} \quad (3.7)$$

gdzie $\omega_l^{(i)}$ jest krokiem lub liczbą losową z zadanego rozkładu. Według powyższej zasady działają algorytmy, takie jak np.:

- przeszukiwanie kukułcze,
- symulowane wyżarzanie,

- algorytmy świetlikowe,
- algorytmy mrówkowe,
- przeszukiwanie z tabu,
- algorytmy pszczele, itp.

Inne algorytmy znajdują kolejne rozwiązanie poprzez odpowiednią modyfikację poprzednich, np.:

- algorytmy genetyczne, nowe punkty powstają poprzez reprodukcję, mutacje, krzyżowanie poprzednich,
- sztuczne systemy immunologiczne,
- sztuczne sieci neuronowe, itp.

Pomysł na algorytm nazwany AIG polega na tym, by tak popularną i intuicyjną zależność (3.3, 3.7) zastąpić zależnością

$$x_l^{(i+1)} = x_l^{(i)} \cdot g_l(\xi) \quad (3.8)$$

lub nawet

$$x_l^{(i+1)} = x_l^{(i)} \cdot g_{l1}(\xi_1) \cdot \dots \cdot g_{lp}(\xi_p) \quad (3.9)$$

Oznacza to, że w kolejnych krokach procesu iteracyjnego, składowe wektora decyzyjnego podlegają modyfikacjom o charakterze „multiplikatywnym”, w przeciwieństwie do modyfikacji „addytywnych” typu (3.3), które wydają się intuicyjne, niezależnie od specyfiki zastosowanego algorytmu. Jak pokazano w dalszej części monografii, można wskazać bardzo proste funkcje $g_{l1}, \dots, g_{lp}$ oraz ich argumenty $\xi_1, \dots, \xi_p$, które zapewniają efektywne rozwiązanie wielu zadań optymalizacyjnych, traktowanych jako modele benchmarkowe.

3.3 Opis „algorytmu innowacyjnego artylerzysty”

3.3.1 Rzut ukośny – fizyczne podstawy balistyki

Zgodnie z elementarnymi pojęciami z fizyki, rzut ukośny to ruch ciała w jednorodnym skierowanym pionowo, polu grawitacyjnym z prędkością początkową o kierunku ukośnym do kierunku pola. Ciało, któremu nadano prędkość v_0 i wystrzelono pod kątem δ do poziomu (płaszczyzna pozioma jest prostopadła do kierunku pola grawitacyjnego), porusza się po paraboli o równaniu (w prostokątnym układzie współrzędnych (d, h)) widocznym poniżej – g oznacza przyspieszenie ziemskie

$$h = \operatorname{tg} \delta \cdot d - \frac{g \cdot d^2}{2 \cdot v_0^2 \cdot \cos^2 \delta} \quad (3.10)$$

Trafienie w cel oznacza, że dla zadanej odległości poziomej d i prędkości v_0 , wysokość h jest równa zero (cel znajduje się na płaszczyźnie poziomej). Wymagana wartość kąta δ może być wyznaczona z zależności

$$\delta = \frac{1}{2} \cdot \arcsin \frac{d \cdot g}{v_0^2} \quad (3.11)$$

Zadanie komplikuje się, jeśli brany jest pod uwagę opór powietrza. Dla najprostszego modelu (opór powietrza proporcjonalny do prędkości ciała) postać wzoru (3.10) ulega istotnej zmianie, albowiem

$$h = \left(\operatorname{tg} \delta + \frac{g}{k \cdot v_0 \cdot \cos \delta} \right) \cdot d + \frac{g}{k^2} \cdot \ln \left(1 - \frac{d \cdot k}{v_0 \cdot \cos \delta} \right) \quad (3.12)$$

przy czym wielkość k jest zdefiniowana jako współczynnik oporu (jednostka 1/s), którego wartość zależy od masy ciała i oporu powietrza. W tym przypadku, aby wyznaczyć kąt strzału, zapewniający trafienie do celu, należy, przyjmując $h = 0$, rozwiązać równanie nieliniowe, powstałe z wyrażenia (3.12). Ponieważ historia balistyki sięga czasów Galileusza i Newtona [209], opracowano szereg metod, analitycznych i empirycznych pozwalających zapewnić celność salwy artyleryjskiej. Należy jednak zauważyć, że krzywa lotu rzeczywistego pocisku ma postać

$$h = \left(\operatorname{tg} \delta + \frac{g}{k \cdot v_0 \cdot \cos \delta} \right) \cdot d + \frac{g}{k^2} \cdot \ln \left(1 - \frac{d \cdot k}{v_0 \cdot \cos \delta} \right) + f_h(\gamma) \quad (3.13)$$

gdzie $f_h(\gamma)$ jest funkcją odpowiadającą oddziaływaniu czynników zakłócających, takich jak zmieniający się opór powietrza, temperatura, wiatr itp. W takim przypadku kąt δ może być rozpatrywany jako zmienna decyzyjna procesu optymalizacyjnego, w którym funkcja celu ma postać


$$F_c(\delta) = |h(\delta)| \rightarrow \min \quad (3.14)$$

Mając na uwadze złożoną postać wyrażenia (3.13) oraz nieokreśloność funkcji $f_h(\gamma)$ do znalezienia wartości kąta strzału może być wykorzystane podejście heurystyczne.

3.3.2 Przykład zastosowania metody AIG do wyznaczenia optymalnego kąta strzału

W celu ilustracji koncepcji algorytmu AIG, rozpatrzono przykład strzelania do celu oddalonego o 11 000 m dla prędkości początkowej $v_0 = 700$ m/s oraz współczynnika oporu powietrza $k = 0,05$ 1/s, optymalna wartość kąta strzału $\delta = 32,94^\circ$. Skuteczność precyzyjnego trafienia do celu z tak dużej odległości jest istotnie zależna od wartości kąta strzału, albowiem dla $\delta' = 32^\circ$ pocisk przeleci 265 m nad celem, a dla $\delta'' = 34^\circ$ upadnie ok. 100 m przed celem. Jak widać, z uwagi na opór powietrza, zwiększanie kąta strzału nie powoduje w tym przypadku wydłużenia jego zasięgu (dla rzutu ukośnego bez uwzględniania oporu powietrza dla kątów od zera do $\pi/4$ im większy kąt tym większy zasięg strzału).

Na poniższym rysunku przedstawiono krzywe balistyczne dla rozważanego przypadku, dla kąta optymalnego $\delta_s = 32,94^\circ$ oraz kątów $\delta' = 32^\circ$ oraz $\delta'' = 34^\circ$.



Rys. 3.2 Krzywe balistyczne dla trzech różnych kątów

Rozpatrując funkcję celu bez czynników zakłócających lot pocisku, należy podkreślić, że zastosowanie metod heurystycznych nie jest niezbędne do wyznaczenia optymalnej wartości kąta strzału δ_s , a co więcej problem ten może zostać rozwiązany na pomoc innych technik obliczeniowych (np. metoda Newtona). Zastosowanie metod heurystycznych dla rozpatrywanego zagadnienia balistycznego może być traktowane jako test ich skuteczności.

Innowacyjny artylerzysta mając do dyspozycji baterię dział i możliwość oddania salwy, dobiera kąt (osobno dla każdego działu) w procesie iteracyjnym, korzystając z zależności (3.9), przy czym doświadczalnie stwierdza, że najlepsze wyniki osiągnie stosując dwa mnożniki korekcyjne ($p = 2$) oraz funkcje g_1 i g_2 o tej samej, specyficznej postaci, czyli

$$\delta^{i+1} = \delta^i \cdot g(\xi_1) \cdot g(\xi_2) \quad (3.15)$$


Zmienne ξ_1 i ξ_2 nie są związane z fizyczną teorią balistyki, aczkolwiek, ponieważ są to kąty $\xi_1 = \alpha, \xi_2 = \beta$ wybierane losowo w procesie losowania z przedziału $(-\alpha_{max}, \alpha_{max})$ oraz $(-\beta_{max}, \beta_{max})$, to nazywamy je „kątami korekcyjnymi”. Losowanie kątów α oraz β z zaznaczonych wyżej przedziałów podlega rozkładowi normalnemu (lub równomiernemu), o wartości średniej równej zero oraz odchyleniu standardowemu, spełniającym zależność $3\sigma = \alpha_{max} = \beta_{max}$ (przyjmowano $\alpha_{max} = \beta_{max} = \frac{\pi}{2}$). Kluczowe znaczenie ma wybór funkcji $g(\alpha)$, $g(\beta)$. Chodzi bowiem o to, by dla wartości „kątów korekcyjnych” α oraz β bliskich zero współczynniki korygujące miały wartość bliską jeden, przy czym dla $\alpha > 0$, $g(\alpha) > 1$, a dla $\alpha < 0$, $g(\alpha) < 1$ (analogicznie dla kąta β). Dla wylosowanych z małym prawdopodobieństwem kątów bliskich α_{max} oraz $-\alpha_{max}$ współczynniki te powinny wyraźnie różnić się od wartości 1 ($g(\alpha) \gg 1$, $g(\alpha) \ll 1$), tak by zapewnić odpowiednio dużą korektę zmiennej decyzyjnej δ . Podobnie przyjmujemy dla kąta β . Kierując się tymi wskazówkami, dobrano funkcję

$$\begin{aligned} g(\alpha) &= \csc(\alpha) = (\cos(\alpha))^{-1} \text{ dla } \alpha > 0 \\ g(\alpha) &= \cos(\alpha) \text{ dla } \alpha < 0 \end{aligned} \quad (3.16)$$

oraz

$$\begin{aligned} g(\beta) &= \csc(\beta) = (\cos(\beta))^{-1} \text{ dla } \beta > 0 \\ g(\beta) &= \cos(\beta) \text{ dla } \beta < 0 \end{aligned} \quad (3.17)$$

Wykres funkcji korekcyjnej pokazano na rys. 3.3.



Rys. 3.3 Przebieg funkcji korekcyjnych

Funkcje korekcyjne mogą być modyfikowane poprzez podnoszenie do odpowiedniej potęgi lub korzystanie z jednego zestawu kątów w obliczeniach. Poprawia to skuteczność algorytmu.

Tym samym ostateczna postać algorytmu AIG, dla pojedynczego działu, ma postać przedstawioną poniżej:

1. wybierz losowo kąt strzału δ_0 ,
2. wyznacz wartość funkcji celu $F_c(\delta_0)$, ustaw licznik iteracji (dla jednej salwy) na $i = 1$, podstaw $\delta^i = \delta_0$,
3. wylosuj „kąt korekcyjny” α^i ; dla $\alpha^i > 0$, $g(\alpha^i) = (\cos(\alpha^i))^{-1}$,
dla $\alpha^i < 0$, $g(\alpha^i) = \cos(\alpha^i)$,
4. wylosuj „kąt korekcyjny” β^i ; dla $\beta^i > 0$, $g(\beta^i) = (\cos(\beta^i))^{-1}$,
dla $\beta^i < 0$, $g(\beta^i) = \cos(\beta^i)$,
5. wyznacz skorygowaną wartość kąta strzału $\delta^{i+1} = \delta^i \cdot g(\alpha^i) \cdot g(\beta^i)$,
6. wyznacz wartość funkcji celu $F_{obj}(\delta^{i+1})$,
7. jeżeli $|F_c(\delta^{i+1}) - F_c(\delta^i)| < \varepsilon$ zakończenie obliczeń – punkt 8, jeżeli nie powrót do punktu 3,
8. zakończenie obliczeń: $\delta_s = \delta^{i+1}$ (optymalny kąt strzału).

3.3.3 Uogólniony algorytm AIG

Dostosowując przedstawiony wyżej algorytm dla salwy wykonanej z m dział, można przedstawić go w postaci pozwalającej na rozwiązywanie dowolnych zadań optymalizacyjnych, tak jak przedstawiono to za pomocą wzorów (3.8) i (3.9). Niezmienne jednak stosowane są dwa mnożniki korygujące ($p = 2$), a ich postać nie ulega zmianie – wykorzystywana jest funkcja cosinus lub jej odwrotność (można je modyfikować poprzez podnoszenie do odpowiedniej potęgi lub korzystanie z jednego zestawu kątów w obliczeniach). Przedział wyboru losowego „kątów korygujących” $(-\alpha_{max}, \alpha_{max})$ oraz $(-\beta_{max}, \beta_{max})$ ulega w trakcie procesu iteracyjnego zawężeniu, zgodnie z zależnościami postępu geometrycznego

$$\begin{aligned}\alpha_{max}^i &= \alpha_{max} \cdot a^i \\ \beta_{max}^i &= \beta_{max} \cdot a^i\end{aligned}\tag{3.18}$$

przy czym liczba a należy do przedziału $(0, 1>$.

Ostatecznie więc uogólniona postać algorytmu AIG może być zapisana w następujący sposób:

1. losowanie wartości początkowych składowych wektora decyzyjnego

$$[\mathbf{x}_1^0] = [x_{11}^0, x_{12}^0, \dots, x_{1n}^0]$$
 pierwszy wektor startowy

...

$$[\mathbf{x}_m^0] = [x_{m1}^0, x_{m2}^0, \dots, x_{mn}^0] \quad m\text{-ty wektor startowy}$$

2. znalezienie wartości funkcji celu dla wektora startowego zmiennych sterujących $F_c(\mathbf{x}_1^0) \dots F_c(\mathbf{x}_m^0)$, $F_{c_best} = \min[F_c(\mathbf{x}_1^0) \dots F_c(\mathbf{x}_m^0)]$,
3. ustawienie licznika iteracji (dla jednej salwy) na $i = 1$, podstawienie $\mathbf{x}_1^i = \mathbf{x}_1^0 \dots \mathbf{x}_m^i = \mathbf{x}_m^0$
4. ustalenie zakresu α_{max}^i i β_{max}^i ,
5. korekta wartości składowych wektora decyzyjnego poprzez współczynniki korekcyjne $g(\alpha)$, $g(\beta)$:

rozwiązanie $j = 1$, losowanie „kątów korekcyjnych” $\alpha_{11}^i \dots \alpha_{1n}^i$ i $\beta_{11}^i \dots \beta_{1n}^i$ według zdefiniowanego rozkładu prawdopodobieństwa, korekta składowych wektora decyzyjnego

$$x_{11}^{(i+1)} = x_{11}^{(i)} \cdot g(\alpha_{11}^i) \cdot g(\beta_{11}^i) \quad \dots \quad x_{1n}^{(i+1)} = x_{1n}^{(i)} \cdot g(\alpha_{1n}^i) \cdot g(\beta_{1n}^i)$$


...

rozwiązanie $j = m$, losowanie „kątów korekcyjnych” $\alpha_{m1}^i \dots \alpha_{mn}^i$ oraz $\beta_{m1}^i \dots \beta_{mn}^i$ według zdefiniowanego rozkładu prawdopodobieństwa, korekta składowych wektora decyzyjnego

$$x_{m1}^{(i+1)} = x_{m1}^{(i)} \cdot g(\alpha_{m1}^i) \cdot g(\beta_{m1}^i) \quad \dots \quad x_{mn}^{(i+1)} = x_{mn}^{(i)} \cdot g(\alpha_{mn}^i) \cdot g(\beta_{mn}^i),$$


6. wyznaczenie wartości funkcji celu $F_c(\mathbf{x}_m^{i+1})$ dla kolejnych rozwiązań $1 \dots m$; sprawdzenie czy wartość funkcji celu dla kolejnego rozwiązania jest mniejsza od wartości funkcji celu z poprzedniej iteracji (jeżeli tak to należy zastąpić to rozwiązanie rozwiązaniem aktualnym – lepszym, a jeżeli nie to pozostawić), identyfikacja rozwiązania q , dla którego funkcja $F_c(\mathbf{x}_q^{i+1}) = \min[F_c(\mathbf{x}_1^{i+1}), \dots, F_c(\mathbf{x}_m^{i+1})]$ osiąga wartość minimalną,
7. sprawdzenie czy dla zidentyfikowanego rozwiązania q zachodzi $F_c(\mathbf{x}_q^{i+1}) < F_{c_best}(\mathbf{x}_{best}^i)$, jeśli tak to przyjęcie go jako kolejnego wektora decyzyjnego w procesie iteracyjnym, czyli $\mathbf{x}_{best}^{i+1} = \mathbf{x}_q^{i+1}$,
8. sprawdzenie kryterium zatrzymania obliczeń ($i+1 = i_{max}$), koniec (punkt 9) lub powrót do punktu 4 ($i = i+1$),
9. koniec obliczeń.

Schemat blokowy algorytmu AIG przedstawiono na rys. 3.4.



Rys. 3.4 Schemat blokowy algorytmu AIG

Na rys. 3.5 przedstawiono porównanie przebiegu najlepszych wartości funkcji celu (zależność 3.14) dla sześciu różnych metod heurystycznych (AIG, CS – przeszukiwanie kukułczane, GA – algorytmy genetyczne, MFO – algorytm optymalizacji ęmy, PSO – rój cząstek, SA – symulowane wyżarzanie).



Rys. 3.5 Przebieg funkcji celu dla różnych algorytmów

Dla 30 powtórzeń obliczeń uzyskano następujące wyniki (najlepszej wartości funkcji celu – BV, średniej – AVE, odchylenia standardowego – STD) w tab. 3.1:

Tab. 3.1 Porównanie wyników obliczeń dla różnych algorytmów

Algorytm	Optymalna wartość zmiennej	BV	AVE	STD
	x			
AIG	32,9421	1,819e-12	1,819e-12	0
CS	32,9421	1,819e-12	1,898e-11	8,31e-11
MFO	32,9421	1,819e-12	1,819e-12	0
SA	32,9421	6,982e-8	6,46	33,57
PSO	32,9421	1,819e-12	56,16	85,78
GA	32,9421	1,89e-4	74,88	91,7

Widać wyraźnie, że proponowany algorytm bardzo dobrze radzi sobie z uzyskaniem rozwiązania. Jak widać z rys. 3.5, dość szybko udaje się znaleźć poszukiwane optimum.

3.4 Strojenie algorytmu

3.4.1 Losowanie kątów

Zmiana obydwu kątów może się odbywać według rozkładu normalnego o średniej równej 0 i odchyleniu standardowym np. $\frac{\alpha_{\max}}{3}$, $\frac{\beta_{\max}}{3}$, gdzie $\alpha_{\max} = 90^\circ$, $\beta_{\max} = 90^\circ$. Oczywiście kąty mogą być przyjmowane dowolnie. Rozkład normalny w obydwu przypadkach uzasadniony jest tym, że podczas celowania do określonego celu zakres zmian kątów nie jest stosunkowo duży. Najbardziej prawdopodobne są niewielkie wartości odchylenia, w kierunku poziomym i pionowym, w stosunku do prostej łączącej cel i lufę działa. Do zmiany obydwu kątów odpowiedni może być również rozkład równomierny, szczególnie wtedy, gdy mamy do czynienia z problemem wielowymiarowym bądź o bardzo dużej liczbie zmiennych. Podczas testowania algorytmu na różnych funkcjach celu zauważono, że dla niektórych problemów lepszym wyborem był właśnie rozkład równomierny.

3.4.2 Zmiany zakresu losowania kątów


W podstawowej wersji algorytmu można założyć pełną losowość zmian kątów α i β w dopuszczalnych granicach, od początku do końca obliczeń. Niekiedy lepsze efekty daje jednak zmniejszanie zakresu zmian kątów wraz ze wzrostem liczby iteracji ponieważ poprawia to zbieżność. Poniżej przedstawiono kilka schematów zmian:

- **geometryczny**, zgodnie ze wzorem:

$$\alpha_t = \alpha_{\max} a^t \quad (3.19)$$

gdzie

np. $\alpha_{\max} = 90^\circ$, a jest liczbą z przedziału $(0,1>$, a t kolejną iteracją,




Rys. 3.6 Przykładowy, geometryczny schemat zmniejszania kątów α i β

- według funkcji exponent, zgodnie ze wzorem:

$$\alpha_t = \alpha_{\max} \cdot e^{(-t \cdot r)} \quad (3.20)$$

gdzie np. $\alpha_{\max} = 90^\circ$, r jest parametrem zmniejszającym (może być odwrotnością iloczynu liczby zmiennych i maksymalnej liczby iteracji), a t kolejną iteracją,




Rys. 3.7 Przykładowy schemat zmniejszania kątów α i β według funkcji exponent

- **liniowy**, zgodnie ze wzorem:

$$\alpha_t = \alpha_{\max} - t \cdot \frac{\alpha_{\max} - \alpha_{\min}}{N} \quad (3.21)$$

gdzie np. $\alpha_{\max} = 90^\circ$, N jest liczbą iteracji, $\alpha_{\min}$ jest wartością końcową kąta, a t kolejną iteracją,



Rys. 3.8 Przykładowy, liniowy schemat zmniejszania kątów α i β

Zmniejszanie dopuszczalnego zakresu zmian kątów α i β uzasadnione jest zbieżnością algorytmu do punktu optymalnego. W początkowej fazie przeszukuje się całą przestrzeń, a w miarę zbliżania się do końca obliczeń, dziedzina funkcji zostaje coraz bardziej ograniczana, tak aby poprawiać wartość funkcji celu i osiągnąć optimum. Możliwe są również inne schematy zmian dopuszczalnego zakresu kątów. Wyróżnić można np. schemat logarytmiczny, według funkcji trygonometrycznych lub wykładniczych.

Skuteczność algorytmu wzrasta, jeżeli zastosuje się kilka „salw”. Sprowadza się to do tego, że po osiągnięciu maksymalnej (założonej) liczby iteracji, powtarza się cykl obliczeń, przyjmując wartości początkowe wektorów zmiennych, równe ostatnim wartościom tychże wektorów w poprzedniej „salwie”.

4. Wybrane testowe funkcje celu z ograniczeniami, dotyczące różnych problemów rzeczywistych z dziedziny mechaniki

Nowe metody optymalizacyjne testowane są przy użyciu typowych funkcji testowych oraz zagadnień z ograniczeniami z różnych dziedzin naukowych. W niniejszym rozdziale przetestowano proponowany algorytm na następujących zagadnieniach z dziedziny mechaniki, bowiem stanowią one standard funkcji testowych do sprawdzania skuteczności nowych metod optymalizacyjnych, podawanych w literaturze [102, 107, 166], [177–186]. Wyróżnić można następujące problemy:

1. projektowania sprężyny,
2. projektowania zbiornika ciśnieniowego,
3. konstrukcji spawanej belki,
4. konstrukcji przekładni zębatej,
5. minimalizacji wagi konstrukcji kratownicy,
6. projektowania belki wspornikowej,
7. minimalizacji odchyłki pionowej belki (dwuteownika),
8. konstrukcji reduktora prędkości.

Wybór powyższych zadań podyktowany był tym, że występują w nich zarówno zmienne decyzyjne ciągłe jak i całkowite, lub całkowite i ciągłe jednocześnie (problem konstrukcji reduktora prędkości). Ponadto liczne ograniczenia podnoszą złożoność zagadnień. Należy również wspomnieć, że prezentowane przykłady testowe opisane są w sposób niezawierający zmiennych niezależnych oraz zależnych od zmiennych decyzyjnych. Każdy z problemów rozwiązano uruchamiając 30 razy pięć algorytmów: AIG (algorytm innowacyjnego artylerzysty), MFO (algorytm optymalizacji ćmy), PSO (algorytm roju cząstek), SA (symulowane wyżarzanie) oraz CS (przeszukiwanie kukiełzane). Dla wszystkich przypadków wyznaczono najlepszą wartość funkcji celu (BV), wartość średnią (AVE) oraz odchylenie standardowe (STD). Dodatkowo, na wykresach, porównano zbieżność każdej metody.

4.1 Problem projektowania sprężyny


Jako pierwszą wykorzystano funkcję trzech zmiennych dotyczącą problemu doboru sprężyny [177, 178]. Funkcja celu opisana jest wzorem:

$$F_c(x) = (x_3 + 2)x_2 \cdot x_1^2 \quad (4.1)$$

przy ograniczeniach:

$$\begin{aligned}
g_1(x) &= 1 - \frac{x_2^3 \cdot x_3}{71785 \cdot x_1^4} \leq 0 \\
g_2(x) &= \frac{4 \cdot x_2^2 - x_1 \cdot x_2}{12566 \cdot (x_2 \cdot x_1^3 - x_1^4)} + \frac{1}{5108 \cdot x_1^2} - 1 \leq 0 \\
g_3(x) &= 1 - \frac{140.45 \cdot x_1}{x_2^2 \cdot x_3} \leq 0 \\
g_4(x) &= \frac{x_1 + x_2}{1.5} - 1 \leq 0 \\
0,05 &\leq x_1 \leq 2 \\
0,25 &\leq x_2 \leq 1,3 \\
2 &\leq x_3 \leq 15
\end{aligned} \tag{4.2}$$

Do rozwiązania powyższego problemu 30 razy uruchomiono wszystkie porównywane algorytmy. Minimalna wartość funkcji celu (uzyskana za pomocą algorytmu AIG) wynosi 0,012665253 i jest to **lepsz** wynik spośród uzyskanych innymi metodami (tab. 4.1). Przykładowy przebieg procesu optymalizacji, przedstawiono na rys. 4.1



Rys. 4.1 Przykładowy przebieg procesu optymalizacji

Tab. 4.1 Porównanie wyników obliczeń z innymi algorytmami

Alg.	Optymalne wartości zmiennych			BV	AVE	STD
	x_1	x_2	x_3			
AIG	0,05169202	0,35678865	11,2848252	0,012665253	0,012833	1,01e-4
MFO	0,051994457	0,36410932	10,868421862	0,0126669	0,013563	1,32e-3
PSO	0,051728	0,357644	11,244543	0,01267	0,013007	9,36e-4
SA	0,051913	0,362121	11,04307	0,012729	0,013493	9,98e-4
CS	0,051690319	0,356747984	11,28722	0,012665259	0,012969	4,64e-4

4.2 Problem projektowania zbiornika ciśnieniowego


W drugim przykładzie wykorzystano funkcję czterech zmiennych, dotyczącą problemu projektowania zbiornika ciśnieniowego [179, 180]. Funkcja celu opisana jest wzorem:

$$F_c(x) = 0,6224 \cdot x_1 \cdot x_3 \cdot x_4 + 1,7781 \cdot x_2 \cdot x_3^2 + 3,1661 \cdot x_1^2 \cdot x_4 + 19,84 \cdot x_1^2 \cdot x_3 \quad (4.3)$$

przy ograniczeniach:

$$\begin{aligned} g_1(x) &= -x_1 + 0,0193 \cdot x_3 \leq 0 \\ g_2(x) &= -x_2 + 0,00954 \cdot x_3 \leq 0 \\ g_3(x) &= -\pi \cdot x_3^2 \cdot x_4 - \frac{4}{3} \cdot \pi \cdot x_3^3 + 1296000 \leq 0 \\ g_4(x) &= x_4 - 240 \leq 0 \\ 0 &\leq x_1 \leq 99 \\ 0 &\leq x_2 \leq 99 \\ 10 &\leq x_3 \leq 200 \\ 10 &\leq x_4 \leq 200 \end{aligned} \quad (4.4)$$

Do rozwiązania powyższego problemu 30 razy uruchomiono wszystkie porównywane algorytmy. Minimalna wartość funkcji celu (uzyskana za pomocą algorytmu AIG) wynosi 5885,346 i jest to **drugi** wynik spośród uzyskanych innymi metodami, tab. 4.2. Przykładowy przebieg procesu optymalizacji, przedstawiono na rys. 4.2.



Rys. 4.2 Przykładowy przebieg procesu optymalizacji

Tab. 4.2 Porównanie wyników obliczeń z innymi algorytmami

Alg.	Optymalne wartości zmiennych				BV	AVE	STD
	x_1	x_2	x_3	x_4			
AIG	0,7781691	0,384651	40,31988	200	5885,346	5897,285	14,76
MFO	0,7781686	0,3846492	40,319645	200	5885,33	6511	587,5
PSO	0,778451	0,384789	40,33424	199,8	5885,815	6336,93	396,48
SA	0,808561	0,399672	41,89436	181,792	5999,775	6770,896	424,4
CS	0,778175	0,384653	40,31994	200	5885,47	5890,8	24,9

4.3 Problem konstrukcji spawanej belki


W trzecim przykładzie wykorzystano funkcję czterech zmiennych, dotyczącą problemu konstrukcji spawanej belki [181, 182]. Funkcja celu opisana jest wzorem:

$$F_c(x) = 1,10471x_1^2 \cdot x_2 + 0,04811 \cdot x_3 \cdot x_4(14 + x_2) \quad (4.5)$$

przy ograniczeniach:

$$\begin{aligned}
 g_1(x) &= \sqrt{\left(\frac{P}{\sqrt{2} \cdot x_1 \cdot x_2}\right)^2 + 2 \cdot \frac{P}{\sqrt{2} \cdot x_1 \cdot x_2} \cdot \frac{M \cdot R}{J} \cdot \frac{x_2}{2 \cdot R} + \left(\frac{M \cdot R}{J}\right)^2} - 13600 \leq 0 \\
 g_2(x) &= \frac{6 \cdot P \cdot L}{x_4 \cdot x_3^2} - 30000 \leq 0 \\
 g_3(x) &= x_1 - x_4 \leq 0 \\
 g_4(x) &= 1,10471 \cdot x_1^2 + 0,04811 \cdot x_3 \cdot x_4 \cdot (14 + x_2) - 5 \leq 0 \\
 g_5(x) &= 0,125 - x_1 \leq 0 \\
 g_6(x) &= \frac{6 \cdot P \cdot L^3}{E \cdot x_3^2 \cdot x_4} - 0,25 \leq 0 \\
 g_7(x) &= P - \frac{4,013 \cdot E \cdot \sqrt{\frac{x_3^2 \cdot x_4^6}{36}}}{L^2} \cdot \left(1 - \frac{x_3}{2 \cdot L} \cdot \sqrt{\frac{E}{4 \cdot G}}\right) \leq 0 \\
 M &= P \cdot \left(L + \frac{x_2}{2}\right), \quad R = \sqrt{\frac{x_2^2}{4} + \left(\frac{x_1 + x_3}{2}\right)^2} \\
 J &= 2 \cdot \sqrt{2} \cdot x_1 \cdot x_2 \cdot \left(\frac{x_2^2}{4} + \left(\frac{x_1 + x_3}{2}\right)^2\right) \\
 E &= 30 \cdot 10^6, \quad G = 12 \cdot 10^6, \quad P = 6000, \quad L = 14 \\
 0,1 &\leq x_1 \leq 2, \quad 0,1 \leq x_2 \leq 10, \quad 0,1 \leq x_3 \leq 10, \quad 0,1 \leq x_4 \leq 2
 \end{aligned} \quad (4.6)$$

Do rozwiązania powyższego problemu 30 razy uruchomiono wszystkie porównywane algorytmy. Minimalna wartość funkcji celu (uzyskana za pomocą algorytmu AIG) wynosi 1,69524717 i jest to **lepsz**y wynik niż uzyskane innymi metodami, tab. 4.3. Przykładowy przebieg procesu optymalizacji, przedstawiono na rys. 4.3.



Rys. 4.3 Przykładowy przebieg procesu optymalizacji

Tab. 4.3 Porównanie wyników obliczeń z innymi algorytmami

Alg.	Optymalne wartości zmiennych				BV	AVE	STD
	x_1	x_2	x_3	x_4			
AIG	0,2057296	3,25312	9,0366239	0,20572964	1,6952472	1,7091	0,01482
MFO	0,2057301	3,25311	9,036603	0,2057306	1,695251	1,8226	0,1659
PSO	0,2057301	3,253114	9,0366129	0,2057301	1,6952489	1,7387	0,14719
SA	0,206416	3,281499	9,006081	0,207127	1,705379	2,2033	0,5579
CS	0,2057252	3,253193	9,036647	0,2057307	1,695263	1,6969	0,0069

4.4 Problem konstrukcji przekładni zębatej


W czwartym przykładzie wykorzystano funkcję czterech zmiennych dotyczącą problemu konstrukcji przekładni zębatej i minimalizacji liczby zębów kół zębatych [102]. Funkcja celu opisana jest wzorem:

$$F_c(x) = \left(\frac{1}{6,931} - \frac{x_2 \cdot x_3}{x_1 \cdot x_4} \right)^2 \quad (4.7)$$

przy ograniczeniach:

$$12 \leq x_1, x_2, x_3, x_4 \leq 60 \quad (4.8)$$

Do rozwiązania powyższego problemu 30 razy uruchomiono wszystkie porównywane algorytmy. Minimalna wartość funkcji celu (uzyskana za pomocą algorytmu AIG) wynosi $2,7009\text{e-}12$ i jest to porównywalny wynik z innymi metodami, tab. 4.4. Problem ten należy do zadań nieliniowej optymalizacji kombinatorycznej z ograniczeniami. Przykładowy przebieg procesu optymalizacji, przedstawiono na rys. 4.4.



Rys. 4.4 Przykładowy przebieg procesu optymalizacji

Tab. 4.4 Porównanie wyników obliczeń z innymi algorytmami

Alg.	Optymalne wartości zmiennych				BV	AVE	STD
	x_1	x_2	x_3	x_4			
AIG	43	19	16	49	$2,7009\text{e-}12$	$6,58\text{e-}10$	$4,97\text{e-}10$
MFO	43	19	16	49	$2,7009\text{e-}12$	$9,18\text{e-}9$	$1,56\text{e-}8$
PSO	49	16	19	43	$2,7009\text{e-}12$	$2,15\text{e-}9$	$4,8\text{e-}8$
SA	49	19	16	43	$2,7009\text{e-}12$	$2\text{e-}6$	$8,81\text{e-}6$
CS	43	16	19	49	$2,7009\text{e-}12$	$1,3\text{e-}10$	$2,59\text{e-}10$

4.5 Problem wagi konstrukcji kratownicy


W piątym przykładzie wykorzystano funkcję dwóch zmiennych dotyczącą problemu wagi konstrukcji kratownicy [102]. Funkcja celu opisana jest wzorem:

$$F_c(x) = l \cdot (2 \cdot \sqrt{2}x_1 + x_2) \quad (4.9)$$

przy ograniczeniach:

$$\begin{aligned}
g_1(x) &= \frac{\sqrt{2}x_1 + x_2}{\sqrt{2}x_1^2 + 2 \cdot x_1 \cdot x_2} \cdot p - \sigma \leq 0 \\
g_2(x) &= \frac{x_2}{\sqrt{2}x_1^2 + 2 \cdot x_1 \cdot x_2} \cdot p - \sigma \leq 0 \\
g_3(x) &= \frac{1}{\sqrt{2}x_2 + x_1} \cdot p - \sigma \leq 0 \\
0 \leq x_1, x_2 \leq 1, \quad l = 100, \quad p = 2, \quad \sigma = 2
\end{aligned}
\tag{4.10}$$

Do rozwiązania powyższego problemu 30 razy uruchomiono wszystkie porównywane algorytmy. Minimalna wartość funkcji celu (uzyskana za pomocą algorytmu AIG) wynosi 263,89584 i jest jednym z lepszych wyników w porównaniu z innymi metodami, tab. 4.5. Przykładowy przebieg procesu optymalizacji, przedstawiono na rys. 4.5.



Rys. 4.5 Przykładowy przebieg procesu optymalizacji

Tab. 4.5 Porównanie wyników obliczeń z innymi algorytmami

Alg.	Optymalne wartości zmiennych		BV	AVE	STD
	x_1	x_2			
AIG	0,788654654	0,408306227	263,89584	263,929	4,555e-2
MFO	0,7882447	0,409466	263,89597	263,966	9,303e-2
PSO	0,7886751	0,4082482	263,895845	264,528	3,4
SA	0,788536	0,408642	263,8959	265,894	3,442
CS	0,78867	0,40902	263,89584	263,9	1,43e-13

4.6 Problem projektowania belki wspornikowej

W szóstym przykładzie wykorzystano funkcję pięciu zmiennych, dotyczącą problemu projektowania belki wspornikowej [183]. Funkcja celu opisana jest wzorem:


$$F_c(x) = 0,0624 \cdot (x_1 + x_2 + x_3 + x_4 + x_5) \quad (4.11)$$

przy ograniczeniach:

$$g(x) = \frac{61}{x_1^3} + \frac{27}{x_2^3} + \frac{19}{x_3^3} + \frac{7}{x_4^3} + \frac{1}{x_5^3} - 1 \leq 0 \quad (4.12)$$

$$0,01 \leq x_1, x_2, x_3, x_4, x_5 \leq 100$$

Do rozwiązania powyższego problemu 30 razy uruchomiono wszystkie porównywane algorytmy. Minimalna wartość funkcji celu (uzyskana za pomocą algorytmu AIG) wynosi 1,306615 i jest to **trzeci** wynik spośród uzyskanych innymi metodami (tab. 4.6). Przykładowy przebieg procesu optymalizacji, przedstawiono na rys. 4.6.



Rys. 4.6 Przykładowy przebieg procesu optymalizacji

Tab. 4.6 Porównanie wyników obliczeń z innymi algorytmami

Alg.	Optymalne wartości zmiennych					BV	AVE	STD
	x_1	x_2	x_3	x_4	x_5			
AIG	5,975182	4,86079	4,479811	3,48178	2,114177	1,306615	1,3067	1,1e-4
MFO	5,98286	4,89297	4,490073	3,461356	2,113086	1,306678	1,3074	7,47e-4
PSO	5,983039	4,879268	4,454203	3,479851	2,142857	1,30661	1,3067	6,66e-5
SA	6,882396	5,304438	4,256104	3,163253	2,936862	1,4067	1,5505	3,28e-2
CS	5,978159	4,875387	4,465149	3,48046	2,139977	1,306602	1,3066	5,21e-7

4.7 Problem konstrukcji dwuteownika


W siódmym przykładzie wykorzystano funkcję czterech zmiennych dotyczącą problemu konstrukcji belki [102]. Funkcja celu opisana jest wzorem:

$$F_c(x) = \frac{5000}{\frac{x_3 \cdot (x_2 - 2 \cdot x_4)^3}{12} + \frac{x_1 \cdot x_4^3}{6} + 2 \cdot x_1 \cdot x_4 \cdot \left(\frac{x_2 - x_4}{2}\right)^2} \quad (4.13)$$

przy ograniczeniach:

$$\begin{aligned} g(x) &= 2 \cdot x_1 \cdot x_3 + x_3 (x_1 - 2 \cdot x_4) - 300 \leq 0 \\ 10 &\leq x_1 \leq 50 \\ 10 &\leq x_2 \leq 80 \\ 0,9 &\leq x_3 \leq 5 \\ 0,9 &\leq x_4 \leq 5 \end{aligned} \quad (4.14)$$

Do rozwiązania powyższego problemu 30 razy uruchomiono wszystkie porównywane algorytmy. Minimalna wartość funkcji celu (uzyskana za pomocą algorytmu AIG) wynosi 0.00653239 i jest to **taki sam** lub lepszy wynik spośród uzyskanych innymi metodami (tab. 4.7). Przykładowy przebieg procesu optymalizacji, przedstawiono na rys. 4.7.



Rys. 4.7 Przykładowy przebieg procesu optymalizacji

Tab. 4.7 Porównanie wyników obliczeń z innymi algorytmami

Alg.	Optymalne wartości zmiennych				BV	AVE	STD
	x_1	x_2	x_3	x_4			
AIG	50	80	2,142857	5	0,00653239	0,0065324	4,98e-17
MFO	50	80	2,142857	5	0,00653239	0,0065324	2,73e-18
PSO	50	80	2,142857	5	0,00653239	0,0065324	4,34e-18
SA	45,53798	79,98	2,36879	5	0,00723	0,01033	3,381e-3
CS	50	80	2,142857	5	0,00653239	0,0065324	4,06e-17

4.8 Problem konstrukcji reduktora prędkości

W ósmym przykładzie wykorzystano funkcję siedmiu zmiennych dotyczącą problemu konstrukcji reduktora prędkości [107, 184, 185, 186]. Funkcja celu opisana jest wzorem:

$$F_c(x) = 0,7854 \cdot x_1 \cdot x_2^2 \cdot (3,3333 \cdot x_3^2 + 14,9334 \cdot x_3 - 43,0934) - 1,508 \cdot x_1 \cdot (x_6^2 + x_7^2) + 7,4777 \cdot (x_6^3 + x_7^3) + 0,7854 \cdot (x_4 \cdot x_6^2 + x_5 \cdot x_7^2) \quad (4.15)$$

przy ograniczeniach:

$$g_1(x) = \frac{27}{x_1 \cdot x_2^2 \cdot x_3} - 1 \leq 0, \quad g_2(x) = \frac{397,5}{x_1 \cdot x_2^2 \cdot x_3^2} - 1 \leq 0, \quad g_3(x) = \frac{1,93 \cdot x_4^3}{x_2 \cdot x_6^4 \cdot x_3} - 1 \leq 0,$$

$$g_4(x) = \frac{1,93 \cdot x_5^3}{x_2 \cdot x_7^4 \cdot x_3} - 1 \leq 0, \quad g_5(x) = \frac{\left[\left(745 \cdot \frac{x_4}{x_2 \cdot x_3} \right)^2 + 16,9 \cdot 10^6 \right]^{0.5}}{110 \cdot x_6^3} - 1 \leq 0,$$

$$g_6(x) = \frac{\left[\left(745 \cdot \frac{x_5}{x_2 \cdot x_3} \right)^2 + 157,5 \cdot 10^6 \right]^{0.5}}{85 \cdot x_7^3} - 1 \leq 0, \quad g_7(x) = \frac{x_2 \cdot x_3}{40} - 1 \leq 0, \quad (4.16)$$

$$g_8(x) = \frac{5 \cdot x_2}{x_1} - 1 \leq 0, \quad g_9(x) = \frac{x_1}{12 \cdot x_2} - 1 \leq 0,$$


$$g_{10}(x) = \frac{1,5 \cdot x_6 + 1,9}{x_4} - 1 \leq 0, \quad g_{11}(x) = \frac{1,1 \cdot x_7 + 1,9}{x_5} - 1 \leq 0,$$

$$2,6 \leq x_1 \leq 3,6, \quad 0,7 \leq x_2 \leq 0,8, \quad 17 \leq x_3 \leq 28, \quad 7,3 \leq x_4 \leq 8,3$$

$$7,3 \leq x_5 \leq 8,3, \quad 2,9 \leq x_6 \leq 3,9, \quad 5 \leq x_7 \leq 5,5$$

Należy zwrócić uwagę na fakt, że w niniejszym zadaniu występuje siedem zmiennych, przy czym 6 ma charakter ciągły natomiast jedna (x_3) jest całkowitoliczbowa. Zatem zagadnienie zalicza się do nieliniowo-kombinatorycznego z ograniczeniami (jedenaście ograniczeń nieliniowych plus siedem ograniczeń na zmienne decyzyjne).

Do rozwiązania powyższego problemu 30 razy uruchomiono wszystkie porównywane algorytmy. Minimalna wartość funkcji celu (uzyskana za pomocą algorytmu AIG) wynosi 2994,471 i jest to **nałepszy** (lub identyczny) wynik spośród uzyskanych innymi metodami, tab. 4.8. Przykładowy przebieg procesu optymalizacji, przedstawiono na rys. 4.8.



Rys. 4.8 Przykładowy przebieg procesu optymalizacji

Tab. 4.8 Porównanie wyników obliczeń z innymi algorytmami

Algorytm	Optymalne wartości zmiennych							BV	AVE	STD
	x_1	x_2	x_3	x_4	x_5	x_6	x_7			
AIG	3,5	0,7	17	7,3	7,715	3,35	5,287	2994,471	2994,5	2e-2
MFO	3,5	0,7	17	7,3	7,715	3,35	5,287	2994,471	3004	32
PSO	3,5	0,7	17	7,3	7,8	3,35	5,287	2994,471	2995	7,05
SA	3,5	0,7	17	7,3	7,8	3,35	5,286	3011	3885	640
CS	3,5	0,7	17	7,9	8,1	3,35	5,287	2994,474	2995	1,72

Podsumowując, należy zauważyć, że proponowany algorytm AIG bardzo dobrze wypada na tle innych metod rojowych. W rozważanych zagadnieniach, stosunkowo szybko udaje się znaleźć właściwy kierunek i minimum funkcji.

5. Wybrane matematyczne testowe funkcje celu

W niniejszym rozdziale przeanalizowano skuteczność algorytmu AIG na dwudziestu dwóch, typowych, matematycznych funkcjach testowych [166, 187, 188, 189, 190]. Ich wybór podyktowany był różnym kształtem (misy, doliny, talerze, strome zbocza) oraz występowaniem wielu optimów. Aby zobrazować trudność i złożoność poszukiwań siedemnaście z nich zilustrowano na wykresie dwuwymiarowym. Do oceny skuteczności działania algorytmu, przedstawionej na końcu rozdziału, użyto wartości średniej i odchylenia standardowego z 30 prób obliczeniowych.

W podpunkcie 5.18 przedstawiono analizę porównawczą dla siedemnastu funkcji testowych, przy czym wyniki uzyskiwane przy pomocy innych algorytmów zaczerpnięto z literatury. Listę tych siedemnastu funkcji przedstawiono poniżej (w celu ich identyfikacji wprowadzono dodatkowe oznaczenia F1 – F17):

1. Goldstein-Price function – F1;
2. Rosenbrock's function – F2;
3. De Jong's function 5 – F3;
4. Schaffer's function 6 – F4;
5. De Jong's function 7 – F5;
6. Griewangk's function – F6;
7. Ackley's function – F7;
8. Egg crate function – F8;
9. Michalewicz function – F9;
10. Rastrigin's function – F10;
11. Langermann's function – F11;
12. Shubert's function – F12;
13. Holder's table function – F13;
14. Drop's wave function – F14;
15. Bukin's function – F15.
16. Funkcja celu z ograniczeniami równościowymi – F16.
17. Funkcja celu z ograniczeniami równościowymi i nierównościowymi jednocześnie – F17.


W podpunkcie 5.19 wykonano dodatkową analizę porównawczą dla 10 wielowymiarowych funkcji testowych (pięć funkcji wzięto z podpunktu 5.18, natomiast pięć pozostałych dodano jako nowe i wszystkie przedstawiono w tab. 5.6). Porównanie przeprowadzono dla siedmiu algorytmów meta-heurystycznych oraz 30, 50 i 100 zmiennych. Obliczenia zostały wykonane w oparciu o kody algorytmów wzięte ze strony Matlab'a, umieszczone tam przez twórców tychże metod. Parametry założone dla poszczególnych heurystyk przedstawione zostały w tab. 5.7.

5.1 Goldstein-Price function – F1

Funkcja Goldstein-Price jest funkcją dwóch zmiennych o postaci:

$$\begin{aligned}
 F_c(x) &= a \cdot b \\
 a &= \left[1 + (x_1 + x_2 + 1)^2 (19 - 14 \cdot x_1 + 3 \cdot x_1^2 - 14 \cdot x_2 + 6 \cdot x_1 \cdot x_2 + 3 \cdot x_2^2) \right] \\
 b &= \left[30 + (2 \cdot x_1 - 3 \cdot x_2)^2 (18 - 32 \cdot x_1 + 12 \cdot x_1^2 + 4 \cdot x_2 - 36 \cdot x_1 \cdot x_2 + 27 \cdot x_2^2) \right] \\
 -2 &\leq x_1, x_2 \leq 2
 \end{aligned} \tag{5.1}$$

Funkcja posiada globalne minimum, równe $F_c(x^*) = 3$ dla $x_1 = 0, x_2 = -1$.




Rys. 5.1 Wykres funkcji Goldstein-Price

5.2 Rosenbrock's function – F2

Funkcja Rosenbrock's jest funkcją n -zmiennych o postaci:

$$\begin{aligned}
 F_c(x) &= \sum_{i=1}^{n-1} \left[100 \cdot (x_{i+1} - x_i^2)^2 + (x_i - 1)^2 \right] \\
 -2.048 &\leq x_i \leq 2.048
 \end{aligned} \tag{5.2}$$

Funkcja posiada globalne minimum, równe $F_c(x^*) = 0$ dla $x_i = 1$.



Rys. 5.2 Wykres funkcji Rosenbrock's dla dwóch zmiennych

5.3 De Jong's function 5 – F3


Funkcja De Jong's 5 jest funkcją dwóch zmiennych o postaci:

$$F_c(x) = \frac{1}{0.002 + \sum_{j=1}^{25} \frac{1}{j + \sum_{i=1}^2 (x_i - a_{ij})^6}} \quad (5.3)$$

$$-65.536 \leq x_1, x_2 \leq 65.536$$

Funkcja posiada globalne minimum, równe

$F_c(x^*) = 0.998004$ dla $x_1 = -32, x_2 = -32$.




Rys. 5.3 Wykres funkcji De Jong's 5

5.4 Schaffer's function 6 – F4

Funkcja Schaffer's jest funkcją n -zmiennych o postaci:

$$F_c(x) = 0.5 + \frac{\left(\sin\left(\sqrt{x_1^2 + x_2^2}\right) - 0.5\right)^2}{\left[1 + 0.001 \cdot (x_1^2 + x_2^2)\right]^2} \quad (5.4)$$
$$-100 \leq x_i \leq 100$$

Funkcja posiada globalne minimum, równe $F_c(x^*) = 0$ dla $x_i = 0$.




Rys. 5.4 Wykres funkcji Schaffer 6 dla dwóch zmiennych

5.5 De Jong's function 7 – F5

Funkcja De Jong's 5 jest funkcją dwóch zmiennych o postaci:

$$F_c(x) = (x_1^2 + x_2^2)^{0.25} \left[\sin^2 \left(50 \cdot (x_1^2 + x_2^2)^{0.1} \right) + 1 \right] \quad (5.5)$$
$$-100 \leq x_1, x_2 \leq 100$$

Funkcja posiada globalne minimum, równe $F_c(x^*) = 0$ dla $x_1 = 0, x_2 = 0$.



Rys. 5.5 Wykres funkcji De Jong's 7


5.6 Griewangk's function – F6

Funkcja Griewangk jest funkcją n -zmiennych o postaci:

$$F_c(x) = \sum_{i=1}^n \frac{x_i^2}{4000} - \prod_{i=1}^n \cos\left(\frac{x_i}{\sqrt{i}}\right) + 1 \quad (5.6)$$

$$-512 \leq x_i \leq 512$$

Funkcja posiada globalne minimum, równe $F_c(x^*) = 0$ dla $x_i = 0$.




Rys. 5.6 Wykres funkcji Griewangk's dla dwóch zmiennych

5.7 Ackley's function – F7

Funkcja Ackley jest funkcją n -zmiennych o postaci:

$$F_c(x) = -20 \cdot \exp \left[-0.2 \sqrt{\frac{1}{n} \sum_{i=1}^n x_i^2} \right] - \exp \left[\frac{1}{n} \sum_{i=1}^n \cos(2 \cdot \pi \cdot x_i) \right] + 20 + e \quad (5.7)$$
$$-30 \leq x_i \leq 30$$

Funkcja posiada globalne minimum, równe $F_c(x^*) = 0$ dla $x_i = 0$.




Rys. 5.7 Wykres funkcji Ackley dla dwóch zmiennych

5.8 Egg crate function – F8

Funkcja Egg crate jest funkcją dwóch zmiennych o postaci:

$$F_c(x) = x_1^2 + x_2^2 + 25 \cdot (\sin^2 x_1 + \sin^2 x_2) \quad (5.8)$$
$$-2\pi \leq x_1, x_2 \leq 2\pi$$

Funkcja posiada globalne minimum, równe $F_c(x^*) = 0$ dla $x_i = 0$.



Rys. 5.8 Wykres funkcji Egg crate

5.9 Michalewicz function – F9


Funkcja Michalewicza jest funkcją n -zmiennych o postaci:

$$F_c(x) = -\sum_{i=1}^n \sin(x_i) \cdot \left[\sin\left(\frac{i \cdot x_i^2}{\pi}\right) \right]^{20} \quad (5.9)$$

$$0 \leq x_i \leq \pi$$

Funkcja posiada globalne minimum, równe

$F_c(x^*) = -1.8013$ dla $n = 2$, $x_1 = 2.2$, $x_2 = 1.57$.



Rys. 5.9 Wykres funkcji Michalewicza dla dwóch zmiennych


5.10 Rastrigin's function – F10

Funkcja Rastrigin jest funkcją n -zmiennych o postaci:

$$F_c(x) = 10 \cdot n + \sum_{i=1}^n (x_i^2 - 10 \cdot \cos(2 \cdot \pi \cdot x_i))$$

$$-5.12 \leq x_i \leq 5.12$$
(5.10)

Funkcja posiada globalne minimum, równe $F_c(x^*) = 0$ dla $x_i = 0$.



Rys. 5.10 Wykres funkcji Rastrigin dla dwóch zmiennych

5.11 Langermann's function – F11


Funkcja Langermann jest funkcją n -zmiennych o postaci:

$$F_c(x) = \sum_{i=1}^5 c_i \cdot \exp\left(-\frac{1}{\pi} \sum_{j=1}^n (x_i - A_{ij})^2\right) \cdot \cos\left(\pi \cdot \sum_{j=1}^n (x_i - A_{ij})^2\right)$$

$$A = \begin{bmatrix} 3 & 5 \\ 5 & 2 \\ 2 & 1 \\ 1 & 4 \\ 7 & 9 \end{bmatrix}, c = [1 \quad 2 \quad 5 \quad 2 \quad 3]$$

$$0 \leq x_i \leq 10$$
(5.11)

Funkcja posiada globalne minimum (dla dwóch zmiennych), równe $F_c(x^*) = -4.1558$ dla $x_1 = 2.7935$, $x_2 = 1.5976$.



Rys. 5.11 Wykres funkcji Langermann dla dwóch zmiennych

5.12 Shubert's function – F12


Funkcja Shubert jest funkcją dwóch zmiennych o postaci:

$$F_c(x) = \left(\sum_{i=1}^5 i \cdot \cos((i+1) \cdot x_1 + i) \right) \left(\sum_{i=1}^5 i \cdot \cos((i+1) \cdot x_2 + i) \right) \quad (5.12)$$

$$-10 \leq x_i \leq 10$$

Funkcja posiada globalne minimum, równe

$F_c(x^*) = -186.7309$ dla $x_1 = -0.8, x_2 = -1.4251$.



Rys. 5.12 Wykres funkcji Shubert

5.13 Holder's table function – F13


Funkcja Holder table jest funkcją dwóch zmiennych o postaci:

$$F_c(x) = - \left| \sin(x_1) \cos(x_2) \exp \left(\left| 1 - \frac{\sqrt{x_1^2 + x_2^2}}{\pi} \right| \right) \right| \quad (5.13)$$

$$-10 \leq x_i \leq 10$$

Funkcja posiada globalne minimum, równe

$$F_c(x^*) = -19.2085 \text{ dla } x_1 = 8.05502, x_2 = 9.66459, \quad x_1 = 8.05502, x_2 = -9.66459, \\ x_1 = -8.05502, x_2 = 9.66459, \quad x_1 = -8.05502, x_2 = -9.66459$$



Rys. 5.13 Wykres funkcji Holder table


5.14 Drop's wave function – F14

Funkcja Drop wave jest funkcją dwóch zmiennych o postaci:

$$F_c(x) = - \frac{1 + \cos \left(12 \sqrt{x_1^2 + x_2^2} \right)}{0.5(x_1^2 + x_2^2) + 2} \quad (5.14)$$

$$-5.12 \leq x_i \leq 5.12$$

Funkcja posiada globalne minimum, równe $F_c(x^*) = -1$ dla $x_1 = 0, x_2 = 0$.



Rys. 5.14 Wykres funkcji Drop wave


5.15 Bukin's function – F15

Funkcja Bukin jest funkcją dwóch zmiennych o postaci:

$$F_c(x) = 100\sqrt{|x_2 - 0.01 \cdot x_1^2|} + 0.01 \cdot |x_1 + 10|$$

$$\begin{aligned} -15 \leq x_1 \leq -5 \\ -3 \leq x_2 \leq 3 \end{aligned} \quad (5.15)$$

Funkcja posiada globalne minimum, równe $F_c(x^*) = 0$ dla $x_1 = -10, x_2 = 1$.



Rys. 5.15 Wykres funkcji Bukin

5.16 Funkcja celu z ograniczeniami równościowymi – F16


Rozpatrywana funkcja celu, o n -zmiennych, opisana jest wzorem [107]:

$$F_c(x) = -(\sqrt{n})^n \cdot \prod_{i=1}^n x_i \quad (5.16)$$

przy ograniczeniach:

$$\begin{aligned} g(x) &= \sum_{i=1}^n x_i^2 = 1 \\ 0 &\leq x_i \leq 1, \quad i = 1, \dots, n \end{aligned} \quad (5.17)$$

Funkcja posiada globalne minimum (dla dwóch zmiennych), równe $F_c(x^*) = -1$ dla $x_1 = 0.7073056$, $x_2 = 0.706908$.



Rys. 5.16 Wykres rozpatrywanej funkcji celu

5.17 Funkcja celu z ograniczeniami równościowymi i nierównościami jednocześnie – F17

Rozpatrywana funkcja celu, o dwóch zmiennych, opisana jest wzorem [107, 220]:


$$F_c(x) = (x_1 - 2)^2 + (x_2 - 1)^2 \quad (5.18)$$

przy ograniczeniach:

$$\begin{aligned}
 g(x) &= x_1 - 2 \cdot x_2 + 1 = 0 \\
 h(x) &= -\frac{x_1^2}{4} - x_2^2 + 1 \geq 0 \\
 -10 &\leq x_1 \leq 10 \\
 -10 &\leq x_2 \leq 10
 \end{aligned}
 \tag{5.19}$$

Funkcja posiada globalne minimum równe

$F_c(x^*) = 1.393454$ dla $x_1 = 0.82288$, $x_2 = 0.91144$.



Rys. 5.17 Wykres rozpatrywanej funkcji celu

5.18 Porównanie wyników obliczeń

W poniższych tabelach przedstawiono najlepsze wartości funkcji celu (BV) dla powyższych siedemnastu (F1–F17) funkcji testowych, wraz ze średnimi wartościami (AV) i odchyleniami standardowymi (STD) uzyskane w 30 próbach. W tab. 5.1 przedstawiono porównanie wyników obliczeń dla funkcji testowych (F1–F6 – dwie zmienne) dla czterech algorytmów (AIG, GA, PSO, SOA). W tab. 5.2 przedstawiono wyniki obliczeń dla funkcji testowych (F7–F15 – dwie zmienne) tylko dla proponowanego algorytmu AIG. W tab. 5.3 przedstawiono porównanie wyników obliczeń dla trzech funkcji testowych (100 zmiennych) dla dziewięciu algorytmów (AIG, MFO, PSO, SOA, GSA, BA, FPA, SMS, FA, GA). W tab. 5.4 i tab. 5.5 zawarto wyniki obliczeń dla dwóch funkcji testowych (F16 i F17). Funkcje F16 i F17 oprócz ograniczeń na zmienne decyzyjne, zawierają również ograniczenia równościowe i nierównościowe.

Poniżej podano wykaz porównywanych metod heurystycznych:

AIG – Algorithm of Innovative Gunner,
GA – Genetic Algorithm,
PSO – Particle Swarm Optimization,
SOA – Seeker Optimization Algorithm,
MFO – Moth-Flame Optimization Algorithm,
GSA – Gravitational Search Algorithm,
BA – Bees Algorithm,
FPA – Flower Pollination Algorithm,
SMS – State of Mater Search,
FA – Firefly Algorithm,
EP – Evolutionary Programming,
MBA – Mine Blast Algorithm,
HS – Harmony Search,
TLBO – Teaching-Learning-Based Optimization,
HM – Homomorphous Mappings.

Tab. 5.1 Porównanie wyników obliczeń (wartości wskaźników BV, AV, STD) dla wybranych algorytmów (AIG, CGA, PSO, SOA) i sześciu funkcji testowych o dwóch zmiennych

Funkcja	Algorytm	F1	F2	F3	F4	F5	F6
BV	AIG	3	7,42e-10	0,9980038	0	8e-65	0
	GA [103]	3	5,25e-5	0,998	0	0,00029844	0,53597
	PSO [103]	3	8,11e-24	0,998004	0	2,8507e-69	0,036907
	SOA [103]	3	0	0,998004	0	0	0
AV	AIG	3	7,42e-8	0,998004	0	7e-45	0
	GA [103]	3	0,011178	0,998004	1,41e-5	0,0073763	0,81229
	PSO [103]	3	4,03e-13	1,097407	0	4,8940e-64	0,101883
	SOA [103]	3	0	0,998	0	0	0
STD	AIG	1,06e-6	1,3e-7	7,7e-8	0	3e-44	0
	GA [103]	1,69e-05	0,014291	1,9642e-10	4,46e-5	0,010015	0,17299
	PSO [103]	3,52e-15	1,19e-12	0,314339	0	1,4540e-63	0,046745
	SOA [103]	1,68e-15	0	1,4803e-16	0	0	0

Tab. 5.2 Wyniki obliczeń (wartości wskaźników BV, AV, STD) metodą algorytmu AIG dla wybranych dziewięciu funkcji testowych o dwóch zmiennych

Funkcja	BV	AV	STD
F7	0	0	0
F8	0	0	0
F9	9,59e-10	1,38e-8	4,7e-15
F10	0	0	0
F11	-4,1558	-4,1558	4,87e-8
F12	-186,73091	-186,73091	8,32e-7
F13	-19,2085	-19,2085	2,85e-8
F14	-1	-1	0
F15	8,32e-5	9e-4	9,6e-5

Tab. 5.3 Porównanie wyników obliczeń (wartości wskaźników BV, AV, STD) dla wybranych algorytmów (AIG , MFO, PSO, GSA, BA, FPA, SMS, FA, GA) i trzech funkcji testowych o 100 zmiennych

Funkcja	Algorytm	F2	F6	F7
AV	AIG	98.84	0	8,88e-16
	MFO [102]	139	0,01908	1,2604
	PSO [102]	77360	12,41865	9,1679
	GSA [102]	741	0,4868	3,7409
	BA [102]	1995125	220,28	15,94609
	FPA [102]	10974	2,716	6,8448
	SMS [102]	6382246	420,5251	19,1326
	FA [102]	3795009	69,65755	14,5677
	GA [102]	31321418	179,9046	17,8462
STD	AIG	0.20068	0	8,88e-16
	MFO [102]	120	0,021732	0,72956
	PSO [102]	51156	4,1658	1,5689
	GSA [102]	781	0,04978	0,17127
	BA [102]	1252388	54,707	0,7749
	FPA [102]	12057	0,7277	1,2499
	SMS [102]	729967	25,25612	0,2385
	FA [102]	759030	12,11393	0,4675
	GA [102]	5264496	32,43956	0,5311

Tab. 5.4 Porównanie wyników obliczeń (wartości wskaźników BV, AV, STD) dla wybranych algorytmów i funkcji testowej F16

Funkcja	Algorytm	F16
BV	AIG	-1
	HM [42]	-0,9997
	GA [224]	-0,99998
	TLBO [205–207]	-1
	MBA [107]	-0,999813
AV	AIG	-0,99997
	HM [42]	-0,9989
	GA [224]	-0,99992
	TLBO [205–207]	-1
	MBA [107]	-0,999147
STD	AIG	3,67e-5
	HM [42]	3,8e-6
	GA [224]	5,99e-5
	TLBO [205–207]	0
	MBA [107]	5,94e-4

Tab. 5.5 Porównanie wyników obliczeń (wartości wskaźników BV, AV, STD) dla wybranych algorytmów i funkcji testowej F17

Algorytm	x_1	x_2	$f(x)$
AIG	0,822875	0,911437	1,39346
EP [222]	0,835	0,9125	1,3772
GA [221]	0,808	0,8854	1,4339
HS [223]	0,8343	0,9121	1,377
MBA [107]	0,822875	0,911437	1,3934649
Optimum [107]	0,82288	0,91144	1,393454

5.19 Dodatkowa analiza porównawcza

Dla 10 wielowymiarowych funkcji celu (tab. 5.6), wykonano obliczenia, zakładając 30, 50 i 100 zmiennych dla każdej z nich oraz porównując z wynikami uzyskanymi za pomocą innych algorytmów, takich jak: Particle Swarm Optimization (PSO), Cuckoo Search (CS), Grey Wolf Optimizer (GWO), Gravitational Search Algorithm (GSA), Artificial Bee Colony (ABC), Biogeography-Based Optimization (BBO). Kody tych algorytmów zostały pobrane ze strony Matlab-a. W obliczeniach przyjęto parametry przedstawione w tab. 5.7. Dla każdego algorytmu wykonano 30 obliczeń i wyznaczono wartość średnią (AVE), odchylenie standardowe (STD) oraz najlepszą wartość funkcji celu (BV) – tab. 5.8, tab. 5.9 i tab. 5.10.

Tab. 5.6 Wielowymiarowe funkcje celu [116, 243]

Id	Funkcja	Wymiar	Limit
F01	$F_{01}(x) = g(x_1, x_2) + g(x_2, x_3) + \dots +$ $+ g(x_{n-1}, x_n) + g(x_n, x_1)$ $g(x, y) = 0.5 + \frac{\sin^2(\sqrt{x^2 + y^2}) - 0.5}{(1 + 0.001 \cdot (x^2 + y^2))^2}$	30, 50, 100	[-100, 100]
F02	$F_{02}(x) = \sum_{i=1}^n x_i + \prod_{i=1}^n x_i $	30, 50, 100	[-10, 10]
F03	$F_{03}(x) = \left[\frac{1}{n-1} \sum_{i=1}^{n-1} \left(\sqrt{s_i} \left(\sin(50 \cdot s_i^{0.2}) + 1 \right) \right) \right]^2,$ $s_i = \sqrt{x_i^2 + x_{i+1}^2}$	30, 50, 100	[-100, 100]
F04	$F_{04}(x) = \max_i \{ x_i , 1 \leq i \leq n\}$	30, 50, 100	[-100, 100]
F05	$F_{05}(x) = \sum_{i=1}^{n-1} \left[100 \cdot (x_{i+1} - x_i^2)^2 + (x_i - 1)^2 \right]$	30, 50, 100	[-30, 30]
F06	$F_{06}(x) = -20 \cdot \exp \left[-0.2 \sqrt{\frac{1}{n} \sum_{i=1}^n x_i^2} \right] -$ $- \exp \left[\frac{1}{n} \sum_{i=1}^n \cos(2 \cdot \pi \cdot x_i) \right] + 20 + e$	30, 50, 100	[-32, 32]
F07	$F_{07}(x) = \sum_{i=1}^n \frac{x_i^2}{4000} + \prod_{i=1}^n \cos \left(\frac{x_i}{\sqrt{i}} \right) + 1$	30, 50, 100	[-600, 600]
F08	$F_{08}(x) = \sum_{i=1}^n (x_i^2 - 10 \cdot \cos(2 \cdot \pi \cdot x_i) + 10)$	30, 50, 100	[-5.12, 5.12]
F09	$F_{09}(x) = \sum_{i=1}^{n-1} -x_i \cdot \sin(\sqrt{ x_i })$	30, 50, 100	[-500, 500]
F10	$F_{10}(x) = \sum_{i=1}^n i \cdot x_i^4 + \text{random}[0,1)$	30, 50, 100	[-1.28, 1.28]

Tab. 5.7 Parametry algorytmów optymalizacyjnych

Algorytm	rozmiar populacji – 30, 50, 100, maksymalna liczba iteracji - 1000
AIG	$0,995 < a < 1, 90 < \alpha_{\max} < 360, 90 < \beta_{\max} < 360$
PSO	$c_1, c_2 = 2, \omega_2 = 0,9, \omega_1 = 0,4$
CS	$p_a = 0,25$
GWO	$\alpha_0 = 2$
GSA	$G_0 = 100, \alpha = 20$
ABC	$a = 1$
BBO	$k_r = 0,2, \alpha = 0,9, p = 0,1$

Tab. 5.8 Wyniki obliczeń (wartości wskaźników BV, AV, STD) dla 30 zmiennych (rozmiar populacji – 30, maksymalna liczba iteracji – 1000)

F		AIG	PSO	CS	GWO	GSA	ABC	BBO
F01	AVE	-14,5	-2,82	-2,75	-9,184	-9,036	-1,317	-5,469
	STD	0	0,888	0,404	1,54	0,719	0,269	0,67
	BV	-14,5	-5,4	-3,53	-12,315	-10,239	-2,102	-6,475
	Poz.	1	5	6	2	3	7	4
F02	AVE	3,9e-19	1,16e-6	0,293	1,17e-34	5,16e-8	23,08	0,329
	STD	6,58e-19	4,05e-6	0,138	1,23e-34	1,02e-8	35,62	0,033
	BV	1,37e-21	6,5e-10	0,09	1,15e-35	3,41e-8	0,0067	0,272
	Poz.	2	4	5	1	3	7	6
F03	AVE	0,001045	2,34	0,225	0,106	0,0171	15,43	0,0719
	STD	0,00134	3,91	0,062	0,197	0,0244	3,02	0,121
	BV	2,31e-5	0,001	0,1176	2,58e-5	2,38e-5	9,86	7,97e-4
	Poz.	1	6	5	4	2	7	3
F04	AVE	1,54e-10	19,144	4,64	2,49e-14	1,56	61,21	0,981
	STD	5,28e-10	5,73	1,64	4,72e-14	1,33	3,8	0,115
	BV	2,32e-14	8,01	1,85	4,94e-16	9,58e-9	50,29	0,771
	Poz.	2	6	5	1	4	7	3
F05	AVE	27,49	65,52	45,94	27,1	36,19	1321221	259,66
	STD	0,818	37,87	35,46	0,816	33,09	617098	398,66
	BV	25,25	27,67	25,82	25,93	25,69	313965	33,21
	Poz.	2	5	4	1	3	7	6
F06	AVE	2,66e-15	17,94	3,15	1,59e-14	8,32e-9	4,24	0,36
	STD	2e-15	5,25	1,11	2,37e-15	1,57e-9	0,828	0,056
	BV	8,88e-16	1,5	1,39	1,15e-14	5,96e-9	2,378	0,259
	Poz.	1	7	5	2	3	6	4
F07	AVE	0	0,035	0,085	0,0036	8,92	0,807	0,763
	STD	0	0,095	0,065	0,0089	4,11	0,126	0,112
	BV	0	8,88e-16	0,00609	0	2,12	0,456	0,444
	Poz.	1	3	4	2	7	6	5
F08	AVE	0	75,66	78,87	0	25,139	234,96	57,7
	STD	0	33,87	12,35	0	6,6	15,13	15,53
	BV	0	30,84	51,13	0	12,93	205,57	26,24
	Poz.	1	5	6	1	3	7	4
F09	AVE	-7692	-8155	-8657	-6023	-2370	-8312	--8145
	STD	336	718	264	732	476	632	580
	BV	-8463	-10138	-9340	-7481	-3603	-9152	-9308
	Poz.	5	4	1	6	7	2	3
F10	AVE	0,002028	0,646357	0,050269	0,0009	0,053439	0,656614	0,007218
	STD	0,001427	0,516729	0,014485	0,000714	0,022249	0,330759	0,002327

F	AIG	PSO	CS	GWO	GSA	ABC	BBO
BV	0,000284	0,048661	0,023843	0,000327	0,028178	0,165203	0,003661
Poz.	2	6	4	1	5	7	3
Średnia pozycja	1,8	5	4	2	4	6,3	4,4
Miejsce	1	6	3	2	3	7	5

Tab. 5.9 Wyniki obliczeń (wartości wskaźników BV, AV, STD) dla 50 zmiennych (rozmiar populacji – 50, maksymalna liczba iteracji – 1000)

F		AIG	PSO	CS	GWO	GSA	ABC	BBO
F01	AVE	-24,4997	-3,53	-3,31	-13,66	-17,97	-1,54	-6,877
	STD	0,0013	1,362	0,377	3,11	0,886	0,346	0,834
	BV	-24,5	-6,77	-4,54	-18,26	-19,512	-2,67	-9,238
	Poz.	1	5	6	3	2	7	4
F02	AVE	6,63e-9	1,8e-3	6,05e+9	1,35e-30	5,5e-8	3,66e+8	1,534
	STD	1,09e-8	6,69e-3	4,84e+9	1,13e-30	9,49e-9	1,92e+9	0,118
	BV	3,49e-12	4,2e-7	86,316	2,49e-31	3,31e-8	180,246	1,243
	Poz.	2	4	7	1	3	6	5
F03	AVE	0,011	1,206	0,936	0,146	0,018	25,743	0,188
	STD	0,008283	4,011	0,147	0,442	0,014	2,772	0,165
	BV	0,0011	0,0059	0,627	0,00011	0,0003	18,077	0,029
	Poz.	1	6	5	3	2	7	4
F04	AVE	1,56	9,63	2,76	5,57e-12	3,65	85,378	2,09
	STD	0,723	1,678	0,467	4,42e-12	1,21	2,82	1,136
	BV	0,264	6,422	1,809	7e-13	0,784	78,19	1,803
	Poz.	2	6	4	1	5	7	3
F05	AVE	48,46	124,83	323,6	47,09	57,41	1,08e+8	446,56
	STD	0,25	57,08	114,84	0,689	29,5	26011772	277,46
	BV	47,94	45,2	131,5	45,23	45,7	51806415	220,45
	Poz.	2	4	5	1	3	7	6
F06	AVE	2,76e-8	19,96	6,719	2,68e-14	5,0e-9	15,173	1,182
	STD	2,44e-8	2,798e-3	2,303	3,8e-15	6,12e-10	1,287	0,128
	BV	6,24e-10	19,951	3,792	1,51e-14	3,88e-9	12,322	0,929
	Poz.	3	7	5	1	2	6	4
F07	AVE	2,65e-11	0,136	0,894	0,001	16,197	30,89	29,04
	STD	4,49e-11	0,383	0,0883	0,0031	4,212	6,2	5,31
	BV	0	7,12e-11	0,652	0	8,308	23,02	18,57
	Poz.	1	3	4	2	5	7	6
F08	AVE	7,89e-12	137,171	181,98	0,323	31,043	528,63	76,84
	STD	3,77e-11	41,378	18,24	1,273	5,832	24,135	14,88
	BV	0	75,616	142,4	0	21,889	483,11	51,64
	Poz.	1	5	6	2	3	7	4
F09	AVE	-11379	-13731	-13098	-9015	-3415	-10145	-13125
	STD	490	892	341	1147	541,28	356	749
	BV	-12497	-15461	-14131	-12182	-4775	-12154	-14435
	Poz.	4	1	3	6	7	5	2
F10	AVE	0,007875	0,944	0,089	0,00091	0,066	73,06	0,0094
	STD	0,004149	0,655	0,026	0,000621	0,022	16,7	0,0025
	BV	0,001304	0,339	0,048	0,00024	0,025	38,75	0,0047
	Poz.	2	6	5	1	4	7	3
Średnia pozycja		1,9	4,7	5	2,1	3,6	6,6	4,1
Miejsce		1	5	6	2	3	7	4

Tab. 5.10 Wyniki obliczeń (wartości wskaźników BV, AV, STD) dla 100 zmiennych (rozmiar populacji – 100, maksymalna liczba iteracji – 1000, B/R – brak rozwiązania)

F		AIG	PSO	CS	GWO	GSA	ABC	BBO
F01	AVE	-45,485	-5,125	-4,511	-27,613	-40,344	-2,105	-9,285
	STD	1,29	1,976	0,537	4,83	0,996	0,205	1,354
	BV	-48,07	-9,128	-6,231	-37,669	-42,634	-2,562	-13,077
	Poz.	1	5	6	3	2	7	4
F02	AVE	0,01	0,462	B/R	1,24e-24	0,0433	B/R	1,497
	STD	0,016	1,603	B/R	5,33e-25	0,089	B/R	0,13
	BV	4,39e-5	0,00817	B/R	5,05e-25	4,41e-8	B/R	1,196
	Poz.	2	4	-	1	3	-	5
F03	AVE	0,027	0,586	4,25	0,474	0,03	39,14	0,746
	STD	0,003	1,964	0,294	0,948	0,02	3,194	0,226
	BV	8,2e-5	0,048	3,712	0,047	0,005	31,02	0,378
	Poz.	1	4	6	3	2	7	5
F04	AVE	15,33	15,49	5,06	4,72e-7	5,195	95,19	4,15
	STD	1,12	1,26	0,55	9,85e-7	0,77	0,64	0,192
	BV	14,2	14,7	3,86	1,1e-8	4,06	93,8	3,8
	Poz.	5	6	3	1	4	7	2
F05	AVE	99,84	465,24	14257	96,74	182,57	1,11e+9	2206,9
	STD	1,03	175,05	3588	0,91	78,49	8,39e+7	359,7
	BV	98,21	259,33	8652	94,9	97,98	7,38e+8	1664,74
	Poz.	2	4	6	1	3	7	5
F06	AVE	8,28e-8	19,96	13,998	4,49e-14	0,0047	20,83	2,63
	STD	7,38e-8	1,278e-3	2,142	4,46e-15	0,0251	0,0706	0,102
	BV	9,07e-10	19,959	7,514	4e-14	2,07e-9	20,69	2,454
	Poz.	2	6	5	1	3	7	4
F07	AVE	3,225e-5	0,1091	4,107	9,25e-4	28,68	2165	2,046
	STD	6,24e-5	0,2233	0,402	0,0028	3,98	184	0,096
	BV	6,97e-9	5,91e-5	3,22	0	20,43	1498	1,879
	Poz.	1	3	5	2	6	7	4
F08	AVE	3,17e-7	322,634	531,03	0,199	38,6	1560	148,94
	STD	5,51e-7	72,56	26,64	0,039	5,53	48,47	18,77
	BV	2,37e-10	175,11	480,35	0	21,89	1460	114,22
	Poz.	1	5	6	2	3	7	4
F09	AVE	-1,914e+4	-2,66e+4	-2,25e+4	-1,77e+4	-5,62e+3	-1,9e+4	-2,5e+4
	STD	1,423e+3	1,49e+3	416	2,48e+3	790,86	1,24e+3	1211
	BV	-2,186e+4	-3,04e+4	-2,32e+4	-2,07e+4	-8,36e+3	-2,05e+4	-2,83e+4
	Poz.	4	1	3	6	7	5	2
F10	AVE	0,013	1,899	0,3	8,15e-4	0,0845	1670	0,024
	STD	0,0084	0,845	0,05	3,14e-4	0,0346	145,8	0,005
	BV	0,002	0,665	0,24	3,54e-4	0,0328	1206	0,017
	Poz.	2	6	5	1	4	7	3
Średnia pozycja		2,1	4,4	4,44	2,1	3,5	6,78	3,8
Miejsce		1	5	6	1	3	7	4

Uzyskane wyniki potwierdzają wysoką skuteczność proponowanego algorytmu. W kilku przypadkach daje on lepsze wyniki od pozostałych metod. Proces obliczeniowy charakteryzuje się tym, że wyniki są powtarzalne. Najlepsza wartość funkcji celu jest zbliżona do średniej wartości a odchylenie standardowe jest mniejsze niż w przypadku innych metod. Dla żadnej funkcji celu, algorytm AIG nie wykazał braku rozwiązania.

6. Zagadnienia optymalizacyjne w elektroenergetyce

6.1 Uwagi wstępne

Tematyka niniejszej monografii dotyczy aspektów związanych z pracą systemu elektroenergetycznego i planowaniem jego rozwoju. Wieloletnie doświadczenia autora, związane z wykonywaniem różnych prac i projektów badawczych, ekspertyz przyłączeniowych dla elementów KSE, potwierdzają aktualność problemów wynikających z uwzględniania nowych źródeł, odbiorów, linii i transformatorów w sieci elektroenergetycznej. Trudności obliczeniowe powodowane są niekiedy specyfiką pracy KSE, a niekiedy restrykcyjnymi obostrzeniami narzucanymi przez Operatorów Systemu. Jednoczesne, ciągłe spełnianie wszystkich wymagań, wiąże się z koniecznością takiej organizacji pracy systemu elektroenergetycznego, aby zachowana była jego niezawodność i bezpieczeństwo przy uwzględnieniu aspektów ekonomicznych.

W swoich doświadczeniach zawodowych autor napotkał wiele takich problemów. Niektóre z nich zostaną przedstawione w kolejnych rozdziałach. Wybór takich, a nie innych zagadnień podyktowany jest tym, że niektóre z nich można zaliczyć do zadań nieliniowych, niektóre (po linearyzacji modelu KSE) do zadań liniowych, a jeszcze inne do kombinatorycznych. Generalnie odzwierciedlają one różnorodność problemów elektroenergetyki.

Rodzi się więc pytanie: W jaki sposób można je rozwiązać? Skuteczną metodą wydaje się być optymalizacja, czyli poszukiwanie najlepszego rozwiązania z punktu widzenia przyjętego kryterium. Możliwe do zastosowania w elektroenergetyce metody optymalizacji zostały opisane w punkcie 2.

Wykaz wybranych do rozwiązania problemów przedstawiony został poniżej:

1. Dopasowanie poziomu mocy generowanej do możliwości przesyłowych gałęzi (linii i transformatorów).
2. Możliwości przyłączania nowych źródeł do systemu elektroenergetycznego.
3. Wygaszanie planów budowy niektórych źródeł w celu uzyskania możliwości przyłączenia innych.
4. Optymalny dobór dławika dla farmy wiatrowej przyłączonej do sieci linia kablową.
5. Optymalizacja rozptyłów mocy biernej w systemie elektroenergetycznym.
6. Minimalizacja różnicy kątów fazorów napięcia przy załączaniu linii elektroenergetycznych.
7. Optymalny dobór parametrów charakterystyk $P(U)$ i $Q(U)$ falowników instalacji fotowoltaicznych.
8. Optymalizacja wyboru punktów podziału w sieci średniego napięcia.

9. Optymalne sterowanie urządzeniami do regulacji przepływów mocy czynnej.
10. Minimalizacja kosztów bilansowania zapotrzebowania na moc w SEE.

6.2 Metody i narzędzia obliczeniowe


Do rozwiązywania problemów z dziedziny elektroenergetyki niezbędny jest odpowiedni warsztat obliczeniowy. Analizy wykonywane są z reguły na pełnym modelu sieci elektroenergetycznej, toteż korzysta się z programów, które są w stanie poradzić sobie z wielowymiarowością np. rozpływów mocy, analizy zwarć, jakości energii, badania stabilności, itp. Wyróżnić można następujące programy, najczęściej wykorzystywane obecnie w krajowej praktyce elektroenergetycznej

- SCC,
- PowerWorld Simulator,
- DigSILENT Power Factory,
- PSLF,
- PLANS,
- MATPOWER,
- ETAP.

Każde z wymienionych narzędzi, posiada różne funkcje, charakterystyczny interfejs użytkownika, czy też format danych. Autor niniejszej monografii, od lat korzysta z oprogramowania PowerWorld Simulator, ze względu na przyjazny interfejs użytkownika oraz możliwość łączenia się z innymi aplikacjami. Ta ostatnia cecha umożliwia wykonywanie różnorodnych analiz, np. rozwiązywanie zadań optymalizacji, poprzez korzystanie z bogactwa funkcji oferowanych przez inne narzędzia, np. Matlab [219]. Do analizy problemów przedstawionych w kolejnych rozdziałach, zastosowano program PowerWorld Simulator, wersja 20 [218]. Oprogramowanie zawiera dodatek SimAuto, który umożliwia łączenie się z zewnętrznymi aplikacjami (Matlab, Excel, Delphi). Program ten służy głównie do obliczania rozpływów mocy w SEE. Posiada on wiele dodatkowych opcji obliczeniowych ułatwiających użytkownikowi pracę. Wspomniany wyżej dodatek SimAuto pozwala łączyć się z aplikacjami zewnętrznymi, edytować parametry elementów analizowanej sieci elektroenergetycznej, wykonywać obliczenia oraz pobierać wyniki obliczeń i zapisywać dane w dowolnym pliku oraz dowolnym miejscu na dysku. Obrazowo można powiedzieć, że SimAuto pełni rolę wymiennego silnika obliczeniowego, który może być wykorzystywany w różnych aplikacjach.

W celu rozwiązywania zadań optymalizacji prezentowanych w niniejszej monografii, wykorzystano środowisko Matlab, w którym napisano skrypt łączący się z dodatkiem SimAuto oraz wywołujący algorytm AIG. Schemat działania pokazano na rys. 6.1.

Aplikacja jest uniwersalna i może służyć do rozwiązywania różnych zagadnień optymalizacyjnych. Użytkownik po jej uruchomieniu może obserwować stan procesu optymalizacji i ewentualnie dokonać jego przerwania. Procedura obliczeniowa rozpoczyna się od przygotowania modelu sieci w formacie akceptowalnym przez PowerWorld Simulator. Jest to plik z danymi SEE z rozszerzeniem *.pwb* (PWB jest domyślnym formatem zapisu danych programu PowerWorld Simulator).



Rys. 6.1 Ogólny schemat organizacji procesu obliczeniowego wykorzystanego w rozwiązywaniu zadań optymalizacyjnych elektroenergetyki

W następnym kroku następuje uruchomienie głównego skryptu w środowisku Matlab, w wyniku którego można się zdalnie połączyć z programem rozpiwowym poprzez dodatek SimAuto. Zmiana parametrów elementów SEE lub pobieranie wyników obliczeń odbywa się za pomocą odpowiednich komend, właściwych dla danego środowiska programistycznego. Po uruchomieniu algorytmu AIG, następują obliczenia optymalizacyjne, po których wyniki zapisywane są w pliku.

Tab. 7.1 Lista linii elektroenergetycznych w analizowanym obszarze sieci

Lp	Pocz.	Kon.	U_n	Obciążalność prądowa	Temperatura pracy (projektowa)
-	-	-	kV	A	°C
1	16	S5	110	325	40
2	16	17	110	548	60
3	16	12	110	548	60
4	21	16	110	205	40
5	18	17	110	205	40
6	19	18	110	205	40
7	19	20	110	205	40
8	32	20	110	300	40
9	32	33	110	205	40
10	34	33	110	205	40
11	34	35	110	205	40
12	36	35	110	600	80
13	S7	36	110	600	80
14	S6	S7	110	1030	80
15	59	S7	110	1030	80
16	59	60	110	1000	80
17	S6	60	110	1000	80
18	S7	58	110	600	80
19	57	58	110	600	80
20	S6	57	110	550	60
21	55	S7	110	550	60
22	56	55	110	550	60
23	56	S6	110	550	60
24	S6	54	110	205	40
25	53	54	110	270	40
26	54	52	110	270	40
27	54	49	110	270	40
28	S7	54	110	600	80
29	38	54	110	550	80
30	37	38	110	550	80
31	32	37	110	270	40

Lp	Pocz.	Kon.	U_n	Obciążalność prądowa	Temperatura pracy (projektowa)
-	-	-	kV	A	°C
32	32	39	110	205	40
33	39	40	110	205	40
34	46	40	110	205	40
35	46	49	110	205	40
36	51	49	110	270	40
37	48	49	110	205	40
38	50	49	110	270	40
39	32	31	110	300	40
40	30	31	110	600	80
41	29	30	110	325	40
42	21	29	110	325	40
43	41	29	110	270	40
44	42	41	110	270	40
45	42	45	110	270	40
46	45	S4	110	270	40
47	47	48	110	205	40
48	47	S4	110	205	40
49	29	28	110	270	40
50	28	27	110	270	40
51	S3	27	110	325	40
52	42	44	110	325	40
53	44	S4	110	325	40
54	43	42	110	325	40
55	S3	43	110	325	40
56	23	29	110	600	80
57	22	23	110	535	80
58	22	S5	110	645	80
59	S5	24	110	325	40
60	25	24	110	325	40
61	26	25	110	325	40
62	S3	26	110	270	40
63	15	S5	110	270	40

Lp	Pocz.	Kon.	U_n	Obciążalność prądowa	Temperatura pracy (projektowa)
-	-	-	kV	A	°C
64	14	15	110	270	40
65	13	14	110	270	40
66	13	4	110	270	40
67	5	4	110	322	40
68	6	5	110	645	80
69	S2	6	110	325	40
70	11	12	110	548	60
71	8	11	110	205	40
72	8	7	110	322	40
73	7	4	110	322	40
74	3	4	110	548	60
75	1	3	110	548	60
76	1	S1	110	270	40
77	11	9	110	305	40
78	9	10	110	205	40

Jeżeli chodzi o dopuszczalne wartości napięć, w poszczególnych węzłach, to utrzymywane były w zakresie od $0,9U_n$ do $1,1U_n$. Analizowany obszar sieci cechuje się dużym nasyceniem planowanych do przyłączenia źródeł. Ponadto w dwóch stacjach systemowych przyłączone są, bądź są planowane do przyłączenia, źródła o mocy rzędu 800÷2000 MW. Istniejące tło generacyjne, czyli źródła (planowane do wybudowania) z uzyskanymi warunkami przyłączenia, przedstawiono w tab. 7.2.

Tab. 7.2 Lista źródeł planowanych do przyłączenia

Lp.	Numer węzła	Moc
		MW
1	16	50
2	16	30
3	3	20
4	8	17
5	11	12
6	9	38
7	10	25
8	14	36
9	19	28

Lp.	Numer węzła	Moc
		MW
10	19	34
11	21	60
12	22	11
13	24	12
14	25	33
15	25	30
16	48	21
17	1	2
18	2	2
19	4	7
20	10	4
21	12	4
22	13	8
23	14	9
24	15	2
25	26	9
26	34	7
27	34	5

Przyłączenie wszystkich wymienionych w tab. 7.2 obiektów jest niemożliwe ze względu na liczne przeciążenia linii elektroenergetycznych, wynikające z kryterium „N-1” (tab. 7.3). W tab. 7.3 przedstawiono wykaz linii wytypowanych do modernizacji na podstawie wykonanej analizy „N-1”.

Tab. 7.3 Wykaz przeciążonych linii i koniecznych zabiegów modernizacyjnych

Lp.	Linia 110 kV wymagająca modernizacji	Maksymalne przeciążenie w stanie N-1, %	Konieczne zabiegi modernizacyjne
	Początek-Koniec		
1	16-S5	5%	dostosowanie do temperatury pracy 60°C
2	21-16	27%	dostosowanie do temperatury pracy 60°C
3	19-18	18%	dostosowanie do temperatury pracy 60°C
4	19-20	18%	dostosowanie do temperatury pracy 60°C
5	21-29	29%	dostosowanie do temperatury pracy 60°C
6	S3-27	50%	dostosowanie do temperatury pracy 60°C
7	S3-43	3%	dostosowanie do temperatury pracy 60°C

Lp.	Linia 110 kV wymagająca modernizacji	Maksymalne przeciążenie w stanie <i>N-1</i> , %	Konieczne zabiegi modernizacyjne
	Początek-Koniec		
8	S5-24	3%	dostosowanie do temperatury pracy 60°C
8	13-14	7%	dostosowanie do temperatury pracy 60°C
10	13-4	10%	dostosowanie do temperatury pracy 60°C
11	5-4	25%	dostosowanie do temperatury pracy 60°C
12	8-7	24%	dostosowanie do temperatury pracy 60°C
13	7-4	13%	dostosowanie do temperatury pracy 60°C
14	1-S1	13%	dostosowanie do temperatury pracy 60°C
15	11-9	56%	dostosowanie do temperatury pracy 60°C
16	55-S7	2%	dostosowanie do temperatury pracy 80°C

Nasuwa się pytanie: Jak rozwiązać problem przeciążania się gałęzi pracujących w układzie zamkniętym? Możliwe są różne rozwiązania:

1. Kosztowna modernizacja sieci;
2. Dopasowanie mocy źródeł do aktualnych możliwości przesyłowych linii elektroenergetycznych i transformatorów;
3. Wygaszenie planów budowy wybranych źródeł;
4. Określenie możliwości przyłączeniowych dla źródeł w SEE;
5. Wykorzystanie urządzeń do regulacji mocy czynnej.

Punkty 2–4 zostały kolejno rozpatrzone w rozdziałach 7.2, 7.3 i 7.4. Punkt 5 rozpatrzone w rozdziale 13.2. W obliczeniach posługiwano się tym samym modelem sieci.

Powyższa tematyka była przedmiotem rozważań autora, m. in. w pracach [133, 134, 136, 137, 138, 139, 142, 144, 147, 149, 157, 160, 161, 162, 167, 169, 171].

7.2 Dopasowanie poziomu mocy generowanej do możliwości przesyłowych gałęzi (linii i transformatorów)

W warunkach pracy, które spotykane są w polskim systemie elektroenergetycznym prawdopodobieństwo wystąpienia niebezpiecznych przeciążeń ważnych linii przesyłowych i 110 kV nie jest stosunkowo duże. Na etapie planowania przyłączeń nowych odbiorców i źródeł, operatorzy bardzo dokładnie badają potencjalne możliwości wystąpienia zagrożeń przeciążeniowych, czyniąc to zresztą przy tak skrajnie pesymistycznych założeniach, że system posiada spory margines bezpieczeństwa. Może jednak zdarzyć się, że dla istniejącej infrastruktury sieciowej, przy wystąpieniu kilku zdarzeń losowych (na przykład upalna pogoda, niespodziewany wzrost zapotrzebowania na moc czynną i bierną, pożar lasu pod jedną linią, awaryjne wyłączenie drugiej) stan przeciążenia pojawi się, a brak reakcji, lub co gorsza wyłączenie kolejnej linii, doprowadzić może do kaskadowych wyłączeń i rozległej awarii systemowej. Istotą rozważań w niniejszym punkcie jest rozwiązanie wielowymiarowego zadania optymalizacyjnego zmieniającego rozkład generacji w taki sposób, aby doprowadzić do likwidacji przeciążenia, przy równoczesnej minimalizacji kosztów takich działań. Generalnie procedura optymalizacji polega na maksymalizowaniu mocy generowanej w OZE przy równoczesnym spełnieniu warunków obciążalności wszystkich linii i zachowaniu bilansu mocy czynnej.

W rozpatrywanej sieci 110 kV pracuje łącznie 27 źródeł (tab. 7.2). Są to źródła już przyłączone bądź planowane do przyłączenia w niedalekiej perspektywie czasowej. Sumaryczna moc tych źródeł to 516 MW. Niektóre z tych źródeł, przede wszystkim te pracujące na średnim napięciu o mocy poniżej 10 MW, traktowane są jako obiekty nieregulowalne (jest ich w sumie 11). W tab. 7.2 są to pozycje od 17 do 27. Zatem, potencjalnych obiektów do regulacji mocy jest w sumie 16 (pozycje od 1 do 16). Przy takich założeniach wykonano obliczenia optymalizacyjne. Za funkcję celu, stanowiącą maksymalizację sumy mocy źródeł przewidzianych do przyłączenia, przyjęto zależność:

$$F_c(\mathbf{x}, \mathbf{y}, \mathbf{z}) = - \sum_{j=1}^{N_z} x_j \quad (7.1)$$

gdzie:

$\mathbf{x} = [P_{G1}, \dots, P_{Gj}]$ – wektor mocy czynnych generowanych przez rozpatrywane źródła wytwórcze OZE, dla których suma mocy ma być maksymalna (wektor zmiennych decyzyjnych),

$\mathbf{y} = [P_{L1}, \dots, P_{Li}, Q_{L1}, \dots, Q_{Li}, P_{Gn1}, \dots, P_{Gnn}]$ – wektor mocy odbieranych oraz mocy generowanych nie podlegających regulacji (wektor zmiennych niezależnych),

$\mathbf{z} = [U_1, \dots, U_i, \delta_1, \dots, \delta_i, P_{Gr1}, \dots, P_{Grk}]$ – wektor fazorów napięć węzłowych oraz mocy generowanych w węzłach zapewniających zbilansowanie systemu (wektor zmiennych zależnych).

Ograniczenia zmiennych decyzyjnych (wektora $\mathbf{x}$) przedstawiono w tab. 7.4:

Tab. 7.4 Ograniczenia zmiennych decyzyjnych (wektora $\mathbf{x}$)

Lp.	P_{Gjmin} MW	P_{Gjmax} MW
1	0	50
2	0	30
3	0	20
4	0	17
5	0	12
6	0	38
7	0	25
8	0	36
9	0	28
10	0	34
11	0	60
12	0	11
13	0	12
14	0	33
15	0	30
16	0	21

Ograniczenia zmiennych zależnych (wektora $\mathbf{z}$) stanowią:

- dopuszczalne wartości napięć w węzłach (generalnie utrzymywane w zakresie od $0,9U_n$ do $1,1U_n$).

Ograniczenia równościowe $g(\mathbf{x}, \mathbf{y}, \mathbf{z})$ stanowią:

- równania węzłowe rozptyłów mocy,
- bilans mocy czynnej rozpatrywanego systemu.

Ograniczenia nierównościowe $h(\mathbf{x}, \mathbf{y}, \mathbf{z})$ stanowią:

- dopuszczalne obciążalności linii elektroenergetycznych,
- dopuszczalne obciążalności transformatorów.

Funkcja celu zawiera w sobie proste sumowanie wybranych elementów wektora zmiennych decyzyjnych, odpowiadających rozpatrywanym węzłom sieci (ich liczba jest określona jako N_z), dla których możliwe jest przyłączenie nowych źródeł. Zmniejszenie generacji mocy czynnej, likwidujące przeciążenia w sieci 110 kV, jest kompensowane reakcją bilansującą dużych elektrowni systemowych (JWCD), które zaliczane są do zmiennych zależnych. Tym samym w procesie obliczeniowym odwzorowany jest skutek regulacji mocy w systemie elektroenergetycznym.

Ponieważ wszystkie metody optymalizacyjne nastawione są z reguły na wyznaczanie minimum, toteż aby znaleźć maksimum, należy funkcję celu wziąć ze znakiem ujemnym.

– **Stan normalny**

Wyniki obliczeń optymalizacyjnych, uzyskanych za pomocą algorytmu AIG, przedstawiono poniżej. W obliczeniach założono 30 strzałów oraz maksymalną liczbę iteracji równą 2000. Losowanie kątów korekcyjnych odbywało się przy wykorzystaniu rozkładu normalnego.

Tab. 7.5 Lista źródeł wraz z optymalnymi wartościami mocy (według algorytmu AIG)

Lp.	Numer węzła	Moc znamionowa	Moc optymalna	Redukcja mocy
		MW	MW	MW
1	16	50	50	0
2	16	30	30	0
3	3	20	20	0
4	8	17	17	0
5	11	12	11	1
6	9	38	38	0
7	10	25	22	3
8	14	36	36	0
9	19	28	27	1
10	19	34	34	0
11	21	60	58	2
12	22	11	11	0
13	24	12	11	1
14	25	33	27	6
15	25	30	25	5
16	48	21	21	0

Aby żadna linia nie ulegała przeciążeniu należy ograniczyć moc źródeł regulowanych sumarycznie od wartości 457 MW do wartości 438 MW (czyli w sumie ograniczyć moc o 19 MW). Przy wartościach mocy przedstawionych w tab. 7.5 żadna linia nie będzie przeciążona, co zostało pokazane w tab. 7.6. Wyróżniono te linie, które stanowią aktywne ograniczenia.


**Tab. 7.6 Lista linii 110 kV wraz z ich obciążeniem w stanie optymalnym
(według algorytmu AIG)**

Lp	Początek	Koniec	U_n	Obciążalność prądowa	Stopień obciążenia
-	-	-	kV	A	%
1	16	S5	110	325	41
2	16	17	110	548	19
3	16	12	110	548	4
4	21	16	110	205	33
5	18	17	110	205	34
6	19	18	110	205	55
7	19	20	110	205	61
8	32	20	110	300	33
9	32	33	110	205	42
10	34	33	110	205	58
11	34	35	110	205	55
12	36	35	110	600	30
13	S7	36	110	600	31
14	S6	S7	110	1030	10
15	59	S7	110	1030	10
16	59	60	110	1000	9
17	S6	60	110	1000	10
18	S7	58	110	600	30
19	57	58	110	600	32
20	S6	57	110	550	25
21	55	S7	110	550	28
22	56	55	110	550	32
23	56	S6	110	550	30
24	S6	54	110	205	75
25	53	54	110	270	34
26	54	52	110	270	28
27	54	49	110	270	47
28	S7	54	110	600	76
29	38	54	110	550	23
30	37	38	110	550	19

Lp	Początek	Koniec	U_n	Obciążalność prądowa	Stopień obciążenia
-	-	-	kV	A	%
31	32	37	110	270	29
32	32	39	110	205	9
33	39	40	110	205	31
34	46	40	110	205	32
35	46	49	110	205	44
36	51	49	110	270	7
37	48	49	110	205	22
38	50	49	110	270	6
39	32	31	110	300	63
40	30	31	110	600	22
41	29	30	110	325	34
42	21	29	110	325	99
43	41	29	110	270	72
44	42	41	110	270	65
45	42	45	110	270	45
46	45	S4	110	270	45
47	47	48	110	205	31
48	47	S4	110	205	47
49	29	28	110	270	63
50	28	27	110	270	55
51	S3	27	110	325	73
52	42	44	110	325	33
53	44	S4	110	325	28
54	43	42	110	325	23
55	S3	43	110	325	43
56	23	29	110	600	47
57	22	23	110	535	55
58	22	S5	110	645	43
59	S5	24	110	325	61
60	25	24	110	325	70
61	26	25	110	325	99
62	S3	26	110	270	88

Lp	Początek	Koniec	U_n	Obciążalność prądowa	Stopień obciążenia
-	-	-	kV	A	%
63	15	S5	110	270	9
64	14	15	110	270	10
65	13	14	110	270	66
66	13	4	110	270	70
67	5	4	110	322	89
68	6	5	110	645	41
69	S2	6	110	325	63
70	11	12	110	548	2
71	8	11	110	205	100
72	8	7	110	322	98
73	7	4	110	322	86
74	3	4	110	548	25
75	1	3	110	548	36
76	1	S1	110	270	66
77	11	9	110	305	100
78	9	10	110	205	67

Poniżej przedstawiono zmienność najlepszych wartości funkcji celu.



Rys. 7.2 Przykładowy przebieg procesu optymalizacji (według algorytmu AIG)

– **Wyłączona linia pomiędzy węzłami nr 29–41**

Wybór tego stanu awaryjnego podyktowany był pojawieniem się stosunkowo dużych przekroczeń prądowych po wyłączeniu tej linii, rzędu nawet 60% ponad wartość dopuszczalną. Wyniki obliczeń optymalizacyjnych, uzyskanych za pomocą algorytmu AIG, przedstawiono poniżej.

Tab. 7.7 Lista źródeł wraz z optymalnymi wartościami mocy (według algorytmu AIG)

Lp.	Numer węzła	Moc znamionowa	Moc optymalna	Redukcja mocy
		MW	MW	MW
1	16	50	50	0
2	16	30	2	28
3	3	20	20	0
4	8	17	6	11
5	11	12	1	11
6	9	38	25	13
7	10	25	25	0
8	14	36	14	22
9	19	28	8	20
10	19	34	12	22
11	21	60	0	60
12	22	11	0	11
13	24	12	12	0
14	25	33	30	3
15	25	30	30	0
16	48	21	21	0

Aby żadna linia nie ulegała przeciążeniu należy ograniczyć moc źródeł regulowanych sumarycznie od wartości 457 MW do wartości 256 MW (czyli w sumie ograniczyć moc o 201 MW). Przy wartościach mocy przedstawionych w tab. 7.7 żadna linia nie będzie przeciążona, co zostało pokazane w tab. 7.8. Wyróżniono te linie, które stanowią aktywne ograniczenia.

Tab. 7.8 Lista linii 110 kV wraz z ich obciążeniem w stanie optymalnym (według algorytmu AIG)


Lp	Początek	Koniec	U_n	Obciążalność prądowa	Stopień obciążenia
-	-	-	kV	A	%
1	16	S5	110	325	47
2	16	17	110	548	28
3	16	12	110	548	7
4	21	16	110	205	51

Lp	Początek	Koniec	U_n	Obciążalność prądowa	Stopień obciążenia
-	-	-	kV	A	%
5	18	17	110	205	25
6	19	18	110	205	38
7	19	20	110	205	21
8	32	20	110	300	25
9	32	33	110	205	60
10	34	33	110	205	76
11	34	35	110	205	67
12	36	35	110	600	37
13	S7	36	110	600	38
14	S6	S7	110	1030	30
15	59	S7	110	1030	11
16	59	60	110	1000	12
17	S6	60	110	1000	11
18	S7	58	110	600	15
19	57	58	110	600	17
20	S6	57	110	550	16
21	55	S7	110	550	5
22	56	55	110	550	9
23	56	S6	110	550	7
24	S6	54	110	205	53
25	53	54	110	270	32
26	54	52	110	270	24
27	54	49	110	270	60
28	S7	54	110	600	84
29	38	54	110	550	34
30	37	38	110	550	30
31	32	37	110	270	49
32	32	39	110	205	25
33	39	40	110	205	49
34	46	40	110	205	50
35	46	49	110	205	58
36	51	49	110	270	6

Lp	Początek	Koniec	U_n	Obciążalność prądowa	Stopień obciążenia
-	-	-	kV	A	%
37	48	49	110	205	20
38	50	49	110	270	5
39	32	31	110	300	52
40	30	31	110	600	18
41	29	30	110	325	28
42	21	29	110	325	26
43	41	29	110	270	0
44	42	41	110	270	9
45	42	45	110	270	20
46	45	S4	110	270	20
47	47	48	110	205	29
48	47	S4	110	205	45
49	29	28	110	270	79
50	28	27	110	270	72
51	S3	27	110	325	99
52	42	44	110	325	11
53	44	S4	110	325	19
54	43	42	110	325	68
55	S3	43	110	325	88
56	23	29	110	600	40
57	22	23	110	535	47
58	22	S5	110	645	45
59	S5	24	110	325	49
60	25	24	110	325	59
61	26	25	110	325	99
62	S3	26	110	270	88
63	15	S5	110	270	33
64	14	15	110	270	32
65	13	14	110	270	59
66	13	4	110	270	64
67	5	4	110	322	61
68	6	5	110	645	27

Lp	Początek	Koniec	U_n	Obciążalność prądowa	Stopień obciążenia
-	-	-	kV	A	%
69	S2	6	110	325	36
70	11	12	110	548	4
71	8	11	110	205	78
72	8	7	110	322	56
73	7	4	110	322	46
74	3	4	110	548	16
75	1	3	110	548	25
76	1	S1	110	270	44

Poniżej przedstawiono zmienność najlepszych wartości funkcji celu.



Rys. 7.3 Przykładowy przebieg procesu optymalizacji (według algorytmu AIG)

Z prowadzonej analizy wynika, że w przypadku wystąpienia w KSE przeciążeń elementów sieci możliwa jest ich likwidacja. Działania operatorskie powinny być wsparte odpowiednim oprogramowaniem wykorzystującym możliwości obliczeniowe w zakresie optymalizacji KSE. Optymalizacja ta powinna w pierwszym rzędzie określać zmiany w rozkładzie generacji mocy w jednostkach konwencjonalnych oraz w źródłach OZE, ale w sytuacjach krytycznych powinna także obejmować strukturę sieci.

7.3 Wygaszanie planów budowy niektórych źródeł w celu przyłączenia wybranych.

Blokowanie miejsc przyłączeniowych w węzłach SEE, przez źródła fikcyjne z uzgodnionymi warunkami przyłączenia, bądź zakresami ekspertyz, jest dużym problemem dla inwestorów, którzy rzeczywiście są zainteresowani szybką realizacją własnej inwestycji, nawet w przypadku konwencjonalnych źródeł wytwórczych. Często spotyka się takie sytuacje, że w danym węźle sieci 110 kV mógłby być przyłączony obiekt o określonej mocy (np. $P_n=50$ MW), ale nie pozwala na to tło generacyjne w analizowanym obszarze sieci. Skądinąd, wiadomo jednak, że niektóre z tych źródeł (głównie farmy wiatrowe) nie zostaną przyłączone, z powodu różnych uwarunkowań ekonomicznych i technicznych. Inwestorzy najbardziej zdeterminowani, gotowi są niekiedy wykupić projekty nierokujące i je wygaszać lub zmniejszać moc przyłączeniową, w celu stworzenia możliwości na przyłączenie źródła w danym miejscu. W monografii przedstawiono metodę typowania źródeł do wygaszenia, w celu likwidacji przeciążeń linii elektroenergetycznych. Dla rozpatrywanego (rys. 7.1) fragmentu sieci 110 kV określono liczbę „fikcyjnych” źródeł (planowanych wstępnie, z uzyskanymi warunkami przyłączenia lub zakresami ekspertyz) do likwidacji, celem umożliwienia przyłączenia jednego z nich, w założonym z góry węźle. Obliczenia wykazały skuteczność proponowanej metody optymalizacji heurystycznej w rozwiązywaniu problemów elektroenergetyki. Wskazano również na celowość prowadzenia takich analiz, aby urealnić plany związane z przyłączaniem źródeł OZE i wyeliminować projekty nierokujące.

Celem niniejszych rozważań było stworzenie możliwości przyłączenia jednego źródła konwencjonalnego o mocy 50 MW poprzez wygaszenie innych źródeł. Istniejące tło generacyjne (tab. 7.2), czyli źródła (na obecną chwilę fikcyjne) z uzyskanymi warunkami przyłączenia i określonymi zakresami ekspertyz, nie pozwala na przyłączenie tego obiektu ze względu na liczne przeciążenia linii elektroenergetycznych, wynikające z kryterium „N-1” (tab. 7.9).

Tab. 7.9 Wykaz przeciążonych linii i koniecznych zabiegów modernizacyjnych

Linia 110 kV wymagająca modernizacji	Maksymalne przeciążenie w stanie N-1 (z analizowanym źródłem), %	Zabiegi modernizacyjne dla układu ze źródłem	Maksymalne przeciążenie w stanie N-1 (bez analizowanego źródła), %	Zabiegi modernizacyjne dla układu bez źródła
Pocz.-Kon.				
16-S5	5%	dostosowanie do temperatury pracy 60°C	0%	-
16-21	27%	dostosowanie do temperatury pracy 60°C	28%	dostosowanie do temperatury pracy 60°C

Linia 110 kV wymagająca modernizacji	Maksymalne przeciążenie w stanie N-1 (z analizowanym źródłem), %	Zabiegi modernizacyjne dla układu ze źródłem	Maksymalne przeciążenie w stanie N-1 (bez analizowanego źródła), %	Zabiegi modernizacyjne dla układu bez źródła
Pocz.-Kon.				
19-18	18%	dostosowanie do temperatury pracy 60°C	19%	dostosowanie do temperatury pracy 60°C
19-20	18%	dostosowanie do temperatury pracy 60°C	17%	dostosowanie do temperatury pracy 60°C
21-29	29%	dostosowanie do temperatury pracy 60°C	14%	dostosowanie do temperatury pracy 60°C
27-S3	50%	dostosowanie do temperatury pracy 60°C	43%	dostosowanie do temperatury pracy 60°C
43-S3	3%	dostosowanie do temperatury pracy 60°C	0%	-
S5-24	3%	dostosowanie do temperatury pracy 60°C	3%	dostosowanie do temperatury pracy 60°C
13-14	7%	dostosowanie do temperatury pracy 60°C	5%	dostosowanie do temperatury pracy 60°C
4-13	10%	dostosowanie do temperatury pracy 60°C	8%	dostosowanie do temperatury pracy 60°C
4-5	25%	dostosowanie do temperatury pracy 60°C	18%	dostosowanie do temperatury pracy 60°C
8-7	24%	dostosowanie do temperatury pracy 60°C	10%	dostosowanie do temperatury pracy 60°C
7-4	13%	dostosowanie do temperatury pracy 60°C	0%	-
S1-1	13%	dostosowanie do temperatury pracy 60°C	6%	dostosowanie do temperatury pracy 60°C
9-11	56%	dostosowanie do temperatury pracy 60°C	57%	dostosowanie do temperatury pracy 60°C
S7-55	2%	dostosowanie do temperatury pracy 60°C	3%	dostosowanie do temperatury pracy 60°C

Aby móc je wszystkie przyłączyć, przeprowadzono analizę „N-1”, która wykazała konieczność modernizacji 16 linii (tab. 7.9, linie przerywane na rys. 7.1). W przypadku tylko trzech z nich, przeciążenie zależy wyłącznie od

przedmiotowego źródła (o mocy 50 MW). W pozostałych przypadkach przeciążenia występują niezależnie od tego czy analizowany obiekt jest przyłączony, czy nie. W ośmiu z nich stwierdzono pogłębianie się przeciążeń w wyniku przyłączenia rozpatrywanej elektrowni. Ponieważ niektóre źródła już pracują (np. na średnim napięciu) toteż założono, że obiekty o mocy poniżej 10 MW są przyłączone na stałe (jest ich w sumie 11 i nie można ich wygasić). W tab. 7.2 są to pozycje od 17 do 27. Na pozycji pierwszej (w tab. 7.2) znajduje się rozpatrywane źródło, które również jest przyłączone na stałe. Potencjalne obiekty do wygaszenia znajdują się na pozycjach od 2 do 16 (w sumie 15 sztuk). Przy takich założeniach wykonano obliczenia optymalizacyjne. Za funkcję celu przyjęto maksymalizację liczby źródeł do przyłączenia:

$$F_c(\mathbf{x}, \mathbf{y}, \mathbf{z}) = -\sum_{j=1}^{N_z} x_j \quad (7.2)$$

gdzie:

$\mathbf{x} = [st_1, \dots, st_j]$ – wektor statusów źródeł OZE przyłączonych do węzła j (wektor zmiennych decyzyjnych),

$\mathbf{y} = [P_{L1}, \dots, P_{Li}, Q_{L1}, \dots, Q_{Li}, P_{Gn1}, \dots, P_{Gnm}]$ – wektor mocy odbieranych oraz mocy generowanych nie podlegających regulacji (wektor zmiennych niezależnych),

$\mathbf{z} = [U_1, \dots, U_i, \delta_1, \dots, \delta_i, P_{Gr1}, \dots, P_{Grk}]$ – wektor fazy napięć węzłowych oraz mocy generowanych w węzłach zapewniających zbilansowanie systemu (wektor zmiennych zależnych).

Ograniczenia zmiennych decyzyjnych (wektora $\mathbf{x}$) związane są z dyskretnym charakterem zmiennych:

- w tym przypadku możliwe są dwie wartości: albo 0 (co oznacza wyłączenie) albo 1 (załączenie i pracę z mocą $P_{\max}$),

Ograniczenia zmiennych zależnych (wektora $\mathbf{z}$) stanowią:

- dopuszczalne wartości napięć w węzłach (generalnie utrzymywane w zakresie od $0,9U_n$ do $1,1U_n$).

Ograniczenia równościowe $\mathbf{g}(\mathbf{x}, \mathbf{y}, \mathbf{z})$ stanowią:

- równania węzłowe przepływów mocy,
- bilans mocy czynnej rozpatrywanego systemu.

Ograniczenia nierównościowe $\mathbf{h}(\mathbf{x}, \mathbf{y}, \mathbf{z})$ stanowią:

- dopuszczalne obciążalności linii elektroenergetycznych,
- dopuszczalne obciążalności transformatorów.

Uwzględniono również kryterium „N-1” (21 wyłączeń – wybrano te gałęzie, których wyłączenia powodują największe przeciążenia). Omawiane zagadnienie należy do optymalizacji kombinatorycznej z ograniczeniami. W obliczeniach (za pomocą algorytmu AIG) założono 30 strzałów oraz maksymalną liczbę iteracji równą 1000. Losowanie kątów korekcyjnych odbywało się przy wykorzystaniu


rozkładu równomiernego. Ponieważ zmienne mają charakter dyskretny (a rozkład jest ciągły), toteż wylosowane wartości zaokrąglano albo do 0 albo do 1.

Wyniki obliczeń przedstawiono w tab. 7.10. Analiza wykazała konieczność wygaszenia dziewięciu źródeł o łącznej mocy 278 MW (oznaczone kolorem szarym w tab. 7.10). Sumaryczna moc źródeł, które mogą być przyłączone wynosi 238 MW. Wydaje się, że jest to zbyt drastyczna redukcja. Jeżeli jednak wziąć pod uwagę to, że znaczna liczba linii wykonana jest przewodami AFL120 mm² o dopuszczalnej temperaturze pracy +40°C (z uwagi na zwisy), dla których dopuszczalna przepustowość, w okresie letnim, wynosi 205 A (ok. 39 MW) to jest to tym bardziej uzasadnione. Otrzymany wynik świadczy o małej przepustowości sieci 110 kV na danym obszarze. Podejmując decyzje dotyczące rozwoju sieci należy przeprowadzić analizę ekonomiczną uzasadniającą czy modernizować sieć, czy próbować wygaszać nierokujące projekty.

Tab. 7.10 Lista źródeł planowanych do przyłączenia wraz z wytypowanymi do wygaszenia, oznaczonymi kolorem szarym (według algorytmu AIG)

Lp.	Numer węzła	Moc
		MW
1	16	50
2	16	30
3	3	20
4	8	17
5	11	12
6	9	38
7	10	25
8	14	36
9	19	28
10	19	34
11	21	60
12	22	11
13	24	12
14	25	33
15	25	30
16	48	21
17	1	2
18	2	2
19	4	7
20	10	4
21	12	4
22	13	8
23	14	9
24	15	2
25	26	9
26	34	7
27	34	5

Na Rys. 7.4 przedstawiono zmienność najlepszych wartości funkcji celu.



Rys. 7.4 Przykładowy przebieg zmienności najlepszej wartości funkcji celu (według algorytmu AIG)

Przedstawiona procedura postępowania, w celu zwiększenia możliwości przyłączeniowych sieci elektroenergetycznej, stanowi alternatywę dla kosztownych modernizacji sieci. W uzasadnionych przypadkach, wygaszanie źródeł, których fizyczna budowa utknęła w martwym punkcie, może być atrakcyjne z ekonomicznego punktu widzenia. Analizując koszty takiego przedsięwzięcia i odnosząc je do kosztów związanych z powiększaniem przepustowości wskazanych linii okaże się, że zaproponowana metoda jest efektywniejsza i o wiele szybsza w realizacji. Oczywiście, należy sobie zdawać sprawę z tego, że nie wszystkie wytypowane obiekty będzie można w rzeczywistości zlikwidować. Jeżeli nie uda się tego wykonać w pojedynczych przypadkach, to można przeprowadzić dodatkową analizę z tymi źródłami (pozostałych nie uwzględniać) i określić konieczne modernizacje. Z pewnością będzie ich o wiele mniej niż pierwotnie.

7.4 Możliwości przyłączania nowych źródeł do systemu elektroenergetycznego

Planując rozwój sieci elektroenergetycznej, jej operator uwzględnia plany rozwoju sektora wytwórczego. W znacznej części plany te zdeterminowane są spodziewanym rozwojem energetyki wiatrowej lub fotowoltaicznej. Analiza odpowiada na pytanie: Jaka jest maksymalna moc źródeł, które można przyłączyć do wybranych węzłów analizowanej sieci? Problem ten rozwiązano jako nieliniowe zadanie optymalizacyjne, maksymalizujące funkcję celu, którą jest sumaryczna moc nowych jednostek wytwórczych, przyłączonych do wskazanych

węzłów sieci (taka sama jak w podpunkcie 7). Analiza wskazuje maksymalną moc jaka może zostać przyłączona do badanego obszaru sieci, przy spełnieniu ograniczeń obciążeniowych, napięciowych i bilansowych. Obliczenia identyfikują również "wąskie gardła" sieciowe wskazując na sposoby ich usunięcia.

Tak jak już wspomniano, niniejszy rozdział zawiera analizę dotyczącą wyznaczania możliwości przyłączeniowych SEE. Z uwagi na cele porównawcze, przyłączanie źródeł OZE założono w tych samych węzłach, co w poprzednim podpunkcie (w sumie 15, pozycje od 2 do 16 w Tab. 7.2). Za funkcję celu, stanowiącą maksymalizację sumy mocy źródeł przewidzianych do przyłączenia, przyjęto zależność:

$$F_c(\mathbf{x}, \mathbf{y}, \mathbf{z}) = - \sum_{j=1}^{N_z} x_j \quad (7.3)$$

gdzie:

$\mathbf{x} = [P_{G1}, \dots, P_{Gi}]$ – wektor mocy czynnych generowanych przez rozpatrywane źródła wytwórcze OZE, dla których suma mocy ma być maksymalna (wektor zmiennych decyzyjnych),

$\mathbf{y} = [P_{L1}, \dots, P_{Li}, Q_{L1}, \dots, Q_{Li}, P_{Gn1}, \dots, P_{Gnm}]$ – wektor mocy odbieranych oraz mocy generowanych nie podlegających regulacji (wektor zmiennych niezależnych),

$\mathbf{z} = [U_1, \dots, U_i, \delta_1, \dots, \delta_i, P_{Gr1}, \dots, P_{Grk}]$ – wektor fazorów napięć węzłowych oraz mocy generowanych w węzłach zapewniających zbilansowanie systemu (wektor zmiennych zależnych).

Ograniczenia zmiennych decyzyjnych (wektora $\mathbf{x}$) stanowią:

- wartości mocy czynnych źródeł OZE, zawierających się w granicach od 0 do 100 MW.

Ograniczenia zmiennych zależnych (wektora $\mathbf{z}$) stanowią:

- dopuszczalne wartości napięć w węzłach (generalnie utrzymywane w zakresie od $0,9U_n$ do $1,1U_n$).

Ograniczenia równościowe $\mathbf{g}(\mathbf{x}, \mathbf{y}, \mathbf{z})$ stanowią:

- równania węzłowe rozplądów mocy,
- bilans mocy czynnej rozpatrywanego systemu.

Ograniczenia nierównościowe $\mathbf{h}(\mathbf{x}, \mathbf{y}, \mathbf{z})$ stanowią:

- dopuszczalne obciążalności linii elektroenergetycznych,
- dopuszczalne obciążalności transformatorów.

Przyjęto również, że źródło w węźle nr. 16 pracuje z mocą równą 50 MW. Analiza ta różni się od analizy z punktu 7.2 tym, że uwzględnione zostało dodatkowo kryterium „N-1” (21 wyłączeń) oraz jako moc maksymalną, przyjęto 100 MW dla każdego źródła (wartość realna dla sieci 110 kV, być może

w niektórych miejscach będzie możliwość przyłączenia źródła o większej mocy niż planowane). Zatem rozwiązywane zadanie należy do zadań SCOPF.


Niniejsza tematyka była szczegółowo analizowana, m.in. w pracach [134, 191, 192, 193]. W obliczeniach (za pomocą algorytmu AIG) założono 30 strzałów oraz maksymalną liczbę iteracji równą 1000. Losowanie kątów korekcyjnych odbywało się przy wykorzystaniu rozkładu normalnego. Wyniki obliczeń optymalizacyjnych przedstawiono w tab. 7.11.

Tab. 7.11 Możliwości przyłączeniowe źródeł (według algorytmu AIG)

Lp.	Numer węzła	Moc
		MW
1	16	50
2	16	9
3	3	78
4	8	0
5	11	5
6	9	10
7	10	3
8	14	3
9	19	0
10	19	23
11	21	0
12	22	3
13	24	24
14	25	16
15	25	25
16	48	93
17	1	2
18	2	2
19	4	7
20	10	4
21	12	4
22	13	8
23	14	9
24	15	2
25	26	9
26	34	7
27	34	5

Okazuje się, że dla wskazanych 16 lokalizacji nowych źródeł, maksymalna moc przyłączeniowa jest na poziomie określonym szacunkowo na 292 MW. Przy takiej wartości mocy, nie nastąpiło naruszenie żadnego z ograniczeń związanych ze wspomnianymi wyżej zagrożeniami. Reasumując, maksymalna moc źródeł, w wybranym obszarze sieci 110 kV wynosi: $292 + 50 + 59 = 401$ MW (biorąc pod uwagę także już pracujące źródła). Spełnione jest wówczas kryterium „N-1”.

Na rys. 7.5 przedstawiono zmienność najlepszych wartości funkcji celu.



Rys. 7.5 Przykładowy przebieg zmienności najlepszych wartości funkcji celu (według algorytmu AIG)

Przeprowadzone badania wskazały, że maksymalne zdolności przyłączeniowe analizowanej sieci elektroenergetycznej mogą być określone w wyniku rozwiązania złożonego zadania optymalizacji nieliniowej z ograniczeniami. Dla rozpatrywanej sieci proponowany algorytm AIG dawał powtarzalne wyniki, uzyskiwane w zbieżnym procesie obliczeniowym. Na podstawie zastosowanej metody heurystycznej określono dla wybranego obszaru maksymalne możliwości przyłączeniowe wybranych węzłów sieci 110 kV.

8. Optymalny dobór urządzenia kompensacyjnego dla farmy wiatrowej przyłączonej do sieci elektroenergetycznej linią kablową

8.1 Wprowadzenie


Niniejszy rozdział poświęcony jest problemom kompensacji mocy biernej w dużych farmach wiatrowych, przyłączonych do sieci elektroenergetycznej za pomocą linii kablowych 110 kV o długości kilkudziesięciu kilometrów. Linie te są budowane jako konsekwencja trudności w uzyskaniu pozwoleń na budowę linii napowietrznych. Ponieważ warunki zabudowy obszarów pomiędzy farmami, a punktami przyłączenia ich do sieci (PCC), uniemożliwiają budowę tańszych linii napowietrznych, wariant kablowy jest jedynym realnym rozwiązaniem. Operatorzy sieci 110 kV określają te linie mianem linii abonenckich, ustalając swoje wymagania w miejscu przyłączenia kabla do PCC, a linie pozostawiając w gestii operatora farmy. Kontrola mocy biernej, której linie kablowe są znaczącym źródłem, jej koordynacja z możliwościami wytwórczymi farmy wiatrowej stają się istotnym problemem projektowym. Teoretycznie proste rozwiązanie polegające na zastosowaniu dławika kompensującego (ang. *Shunt Reactor* – SR) na końcu linii wiąże się z wyborem jednostki o ustalonej indukcyjności (*Fixed SR*). Jednakże zmienność warunków pracy sieci (napięcie w PCC, moc czynna farmy wiatrowej) oraz niepewność parametrów konstrukcyjnych kabla i dławika (nie są to elementy produkowane w sposób powtarzalny), zmuszają do korzystania z innych rozwiązań: dławików regulowanych pod obciążeniem za pomocą odczepów (*Variable SR*) oraz kosztownych układów FACTS z płynną regulacją (SVC) czy STATCOM.

Rozpatrywana tematyka była przedmiotem badań autora w pracach [146, 150, 154, 155, 163, 164].

Farmy wiatrowe przyłączone do systemu elektroenergetycznego powinny świadczyć na jego rzecz określone usługi systemowe. Niezależnie od tego czy będą to usługi opłacane przez operatora systemu, czy też ich świadczenie będzie wynikało z obowiązków przyjętych przez strony w umowie o przyłączenie. Z technicznego punktu widzenia farma i jej infrastruktura muszą spełniać określone wymagania techniczne. Część tych wymagań wiąże się z problemem generacji przez farmę mocy biernej o określonej wartości.

Dotychczasowe wymagania Operatorów sieci dla farm wiatrowych dotyczące mocy biernej, wynikają między innymi z konieczności utrzymania dopuszczalnej wartości napięcia oraz odpowiedniego współczynnika mocy w miejscu przyłączenia. Regulacja napięcia i mocy biernej w dużych farmach wiatrowych powinna się odbywać w trybie autonomicznym, przy współpracy z nadrzędnym systemem sterowania i regulacji napięcia i mocy biernej.

Zapisy IRiESP oraz IRiESD wymagają od farm wiatrowych takiego wyposażenia, aby możliwe było zapewnienie przez nieokreślonych warunków napięciowych w miejscu przyłączenia. W warunkach przyłączenia podawane są wymagania odnośnie charakterystyki statycznej działającego lokalnie układu regulacji napięcia rys. 8.1.



Rys. 8.1 Charakterystyka statyczna układu regulacji napięcia farmy wiatrowej [212]

Przedstawiona charakterystyka jest sparametryzowana. Zakresy nastawcze parametrów określone są w IRiESP, przy czym parametryzacja odbywa się indywidualnie dla danej farmy wiatrowej. Wymaganie związane z regulacją mocy biernej dotyczy utrzymania odpowiedniego współczynnika mocy, zarówno jeżeli chodzi o pobór jak i generację mocy biernej. Często w warunkach przyłączenia farm wiatrowych można znaleźć zapisy mówiące o dwóch stanach:

- tzw. „jałowym”, co oznacza postój (brak generacji mocy czynnej). W takiej sytuacji Operator wymaga, aby współczynnik mocy w miejscu przyłączenia był bliski jedności,
- pracy, co wiąże się z koniecznością utrzymania współczynnika mocy w miejscu przyłączenia w granicach od $\cos\varphi = 0,95$ (o charakterze indukcyjnym) do $\cos\varphi = 0,95$ (o charakterze pojemnościowym) w pełnym zakresie obciążenia mocą czynną. Dodatkowo, przy obciążeniu mocą czynną niższą od osiągalnej, należy udostępnić całą dostępną moc bierną w zakresie poza wymaganym współczynnikiem mocy.

W przypadku farmy wiatrowej o dużej mocy (rzędu kilkudziesięciu megawatów), przyłączonej do systemu za pomocą linii kablowej 110 kV o znacznej długości (rzędu kilkudziesięciu kilometrów) dobór urządzenia kompensacyjnego musi opierać się na dwóch powyższych stanach pracy FW.


Stan, w którym farma wiatrowa nie generuje mocy czynnej (postój) wpływa na moc znamionową głównego urządzenia kompensacyjnego – zachodzi wówczas konieczność przede wszystkim kompensacji pojemności linii kablowej 110 kV oraz sieci SN FW, która odgrywa w tym przypadku mniejszą rolę. Stan pracy FW, szczególnie przy obciążeniu mocą czynną bliską znamionowej, wpływa na określenie możliwości regulacyjnych urządzenia kompensacyjnego (np. liczby zaczepów dławika) lub też dobór dodatkowych urządzeń umożliwiających taką regulację (np. baterii kondensatorów). Przy pełnym obciążeniu mocą czynną możliwości generacji mocy biernej przez turbiny wiatrowe są niekiedy niewystarczające do utrzymania odpowiedniej wartości współczynnika mocy.

Wymagania unijne zostały zawarte w Rozporządzeniu Unii Europejskiej nr 631 z 2016 r. [213], które wprowadziło szereg warunków dla źródeł wytwórczych przyłączonych do sieci elektroenergetycznej (stąd akronim opisujący to rozporządzenie – RfG – *requirements for generation*). Farmy wiatrowe o mocy powyżej 50 MW zaliczane są do źródeł typu C oraz D, a ponadto ustawodawca klasyfikuje je jako moduły parku energii (PPM) stawiając przed nimi określone wymagania dotyczące punktu przyłączenia do SEE (dla mocy powyżej 50 MW jest to z reguły sieć o napięciu 110 kV). Niektóre z tych wymagań, dotyczących zdolności do generacji i poboru mocy biernej przez PPM zacytowano poniżej:

Art.21 ust.3c

1. *właściwy operator systemu w porozumieniu z właściwym OSP określa wymogi dotyczące zdolności do zapewnienia generacji mocy biernej i określa profil $P-Q/P_{max}$, który może mieć dowolny kształt w granicach, w których moduł parku energii musi mieć zdolność do zapewnienia mocy biernej przy mocy mniejszej niż moc maksymalna;*
2. *profil $P-Q/P_{max}$ musi zostać określony przez każdego właściwego operatora systemu w porozumieniu z właściwym OSP, zgodnie z poniższymi zasadami:*
 - *profil $P-Q/P_{max}$ nie może przekraczać obwiedni profilu $P-Q/P_{max}$ przedstawionego jako obwiednia wewnętrzna na rysunku poniżej,*
 - *zakres Q/P_{max} obwiedni profilu $P-Q/P_{max}$ został określony dla każdego obszaru synchronicznego (...),*
 - *zakres mocy czynnej profilu $P-Q/P_{max}$ przy zerowej wartości mocy biernej wynosi 1 jednostkę względną,*

- profil $P-Q/P_{\max}$ może mieć dowolny kształt i musi uwzględniać warunki dotyczące zdolności do generacji mocy biernej przy wartości mocy czynnej równej zero oraz
- położenie obwiedni profilu $P-Q/P_{\max}$ musi się mieścić w granicach stałej obwiedni zewnętrznej przedstawionej na Rys. 8.2




Rys. 8.2 Określenie zakresu wymagań odnośnie możliwości generacji mocy biernej dla modułów parku energii (PPM) wg wymagań rozporządzenia UE 2016/631 [213]

Oznacza to możliwość wybrania przez operatora sieci charakterystyki o dowolnym kształcie mieszczącym się w granicach obwiedni zewnętrznej, charakterystyki widocznej na rys. 8.2, a od właściciela farmy wiatrowej (czyli ogólnie PPM) konieczność spełnienia tego wymagania w każdej chwili pracy farmy („chwila” jest rozumiana jako określony przedział czasu, a wartości mocy biernej i czynnej są uśrednione dla tego okresu czasu).


8.2 Opis sieci testowej

Zgodnie z definicją modułów parku energii [213]: „moduł parku energii” („PPM”) oznacza jednostkę lub zestaw jednostek wytwarzających energię elektryczną, która(-y) jest przyłączona(-y) do sieci w sposób niesynchroniczny lub poprzez układy energoelektroniki, i która(-y) ma również jeden punkt przyłączenia do systemu przesyłowego, systemu dystrybucyjnego, w tym zamkniętego systemu dystrybucyjnego, lub systemu HVDC”, rozumiany jest on jako całość, czyli linia wewnętrzna 110 kV, transformator 110/SN, sieć kablowa SN, generatory turbin wiatrowych z układami przekształtnikowymi SN/nn. Taki układ przedstawiono na rys. 8.3.



Rys. 8.3 Uproszczony schemat przyłączenia farmy wiatrowej do sieci 110 kV

Sieci widocznej na rys. 8.3 można przyporządkować model dokładny (w sensie obliczeń rozptylowych) widoczny na rys. 8.4. Taki model może być przedmiotem analizy prowadzonej za pomocą specjalistycznego oprogramowania „rozptylowego”. Możliwe jest jednak zastosowanie modelu uproszczonego, dla którego zależności bilansowe dla mocy biernej w punkcie PCC mogą być wyrażone za pomocą prostych wzorów.



Rys. 8.4 Schemat modelu obliczeniowego R, X, B sieci wewnętrznej 110/30 kV farmy wiatrowej (wymagania w zakresie mocy biernej dotyczą punktu przyłączenia do sieci 110 kV, PCC)

Na rys. 8.4 pokazano również dławiki po stronie WN i SN oraz baterię kondensatorów. O tym, czy po stronie SN znajdzie konieczność stosowania dodatkowych urządzeń do kompensacji mocy biernej decyduje dobór głównego urządzenia kompensacyjnego, przyłączonego po stronie 110 kV, takiego jak:

- dławik o stałej indukcyjności FSR (ang. *Fixed Shunt Reactor*), którego moc bierna pobierana może być wyrażona zależnością

$$Q_{FSR} = \frac{U^2}{X_{Ln}} \quad (8.1)$$

gdzie:

Q_{FSR} – moc dławika, X_{Ln} – reaktancja dławika, U – napięcie w miejscu przyłączenia dławika.

- dławik z zaczepami o zmiennej indukcyjności VSR (ang. *Variable Shunt Reactor*), którego moc bierna pobierana może być wyrażona zależnością

$$Q_{VSR} = Q_{Ln} \cdot (U / U_N)^2 \cdot \left(\frac{100}{100 + N \cdot \Delta R} \right)^2 \quad (8.2)$$


gdzie:

$$Q_{Ln} = \frac{U_N^2}{X_{Ln}} - \text{moc dławika przy } U_N \text{ i przy znamionowej liczbie zwojów}$$

Z_N, X_{LN} – reaktancja dławika, Q_{VSR} – moc dławika przy wybranym zaczeple N oraz dla napięcia U , N – numer zaczeple (dodatni, ujemny lub zero), ΔR – skok zaczeple w % (np. 1,5%, 2%, 2,5%, 3%).

- układy FACTS z płynną regulacją SVC (ang. *Static Var Compensator*) oraz STATCOM. Ze względu na wysoki koszt – są stosowane w praktyce przyłączania farm wiatrowych stosunkowo rzadko.

Biorąc pod uwagę rozporządzenie [213], operator sieci może określić charakterystykę wymaganą o kształcie widocznym na rys. 8.5, a od właściciela farmy zażądać konieczności jej spełnienia w każdej chwili pracy.



Rys. 8.5 Charakterystyka mocy biernej w punkcie przyłączenia jednostki PPM (Power Park Module) ustalona zgodnie z wymaganiami rozporządzenia UE 2016/631 przez operatora sieci, dla rozpatrywanej farmy wiatrowej

Zgodnie z kształtem powyższej charakterystyki, wymagania operatora sieci względem PPM, mogą być zapisane za pomocą następujących zależności:

$$\text{dla } P_{FW} > 0 \text{ moc bierna wymagana } -0,35 P_{nFW} \leq Q_{PCC} \leq 0,4 P_{nFW} \quad (8.3)$$

$$\text{dla } P_F = 0 \text{ moc bierna wymagana } Q_{PCC} = 0 \quad (8.4)$$

Brak gotowości do spełnienia wymagania odnośnie charakterystyki rys. 8.5 nie podlega obecnie zadanej z góry penalizacji finansowej. Może się bowiem zdarzyć, że w okresie roku operator systemu ani razu nie zażąda od właściciela PPM maksymalnej generacji lub minimalnego poboru mocy biernej. Z drugiej jednak strony jeśli deficyty te wystąpią, to ich skutki systemowe obciążą go dotkliwie. Nie można również wykluczyć wprowadzenia obowiązku gotowości w zakresie generacji/poboru mocy biernej do taryfy OSD, lub przeciwnie, potraktowania go jako odpłatnej usługi systemowej.

W przypadku stanu „jałowego” (farma jest przyłączona do sieci ale nie generuje mocy czynnej) współczynnik mocy w punkcie przyłączenia powinien być bliski jedności. Zgodnie z postanowieniami [214], niezerowy stan generacji mocy biernej, przy zerowej generacji mocy czynnej podlega opłacie rocznej

$$K_Q = \sum_{j=1}^{k_j} k_k \cdot e \cdot \Delta Q_j \cdot T_j \quad (8.5)$$

gdzie:

k_k – współczynnik (dla sieci 110 kV wynosi on 0,5),

e – cena energii elektrycznej wg. rocznej wyceny URE,


ΔQ_j – niebilansowanie do zera mocy biernej w j -tym okresie jałowej pracy farmy,

T_j – czas trwania j -tego okresu pracy jałowej farmy.


8.3 Obliczenia

Do obliczeń założono, że rozpatrywana farma wiatrowa o mocy 60 MW (składająca się z 30 turbin wiatrowych o mocy 2 MW każda, sieć wewnętrzna SN FW składa się z sześciu ciągów linii kablowych 30 kV) przyłączona jest do sieci elektroenergetycznej za pomocą linii kablowej (żyły miedziane o przekroju 630 mm²) o długości 20 km. Przyjęto, że napięcie w punkcie przyłączenia wynosi 1,05 U_n . Charakterystyka $Q(P)$ dla analizowanej farmy wiatrowej przedstawiona została na rys. 8.6.


Roczna zmienność prędkości wiatru (w rozpatrywanym przypadku wartość maksymalna 18,6 m/s, średnio w ciągu roku 6,75 m/s) skutkuje zmianami generowanej mocy czynnej przez farmę – od wartości maksymalnej – 60 MW do zera. Okres pracy jałowej, czyli takiej, dla której prędkość wiatru jest mniejsza od 4 m/s wynosi ok. 1500 godzin. Wykres odpowiadający zmienności generacji mocy czynnej w ciągu roku przedstawiono na rys. 8.7. Zgodnie ze sformułowanymi wyżej wymaganiami możliwości wytwórcze farmy w zakresie mocy biernej powinny kształtować się zgodnie z wykresem widocznym na rys. 8.8.



Rys. 8.6 Charakterystyka mocy biernej w funkcji mocy czynnej FW



Rys. 8.7 Wykres rocznego przebiegu mocy czynnej osiągalnej przez rozpatrywaną farmę wiatrową o mocy 60 MW



Rys. 8.8 Wymagania w zakresie generacji i poboru mocy biernej przez farmę wiatrową o mocy 60 MW określone na podstawie charakterystyki z rys. 8.5 (zgodnie z rozporządzeniem UE 2016/631)

Bilansując zdolności generacyjne generatorów poszczególnych wiatraków, generację mocy biernej w kablach SN i kablu 110 kV oraz uwzględniając zmieniające się wraz z kwadratem generacji mocy czynnej straty podłużne, można określić maksymalne i minimalne wartości mocy biernej dostępne w PCC dla rozpatrywanej chwili j -tej. Okazuje się, że dla pewnych warunków, wymagania w zakresie generacji i poboru mocy biernej określone zgodnie z charakterystyką z rys. 8.5 nie mogą być spełnione, bowiem

$$Q_{\max_PCCj} < Q_{\max_req} \quad (8.6)$$

$$Q_{\min_PCCj} < Q_{\min_req} \quad (8.7)$$

oraz dodatkowo

$$Q_{PCCj} \neq 0 \text{ dla } P_{FW} = 0 \quad (8.8)$$

przy czym

$$Q_{\max_req} = 0,4 \cdot P_{nFW} = 24 \text{ Mvar}$$

$$Q_{\min_req} = -0,35 \cdot P_{nFW} = -21 \text{ Mvar}$$

Zbiorczą ocenę spełnienia tych wymagań można określić wprowadzając odpowiednie wskaźniki, zgodnie z zależnościami:

$$A_{Q\max} = \sum_{j=1}^{k_j} Q_{\max_req} T_j \quad (P_{FWj} > 0) \quad (8.9)$$

$$A_{Q\min} = \sum_{j=1}^{k_j} Q_{\min_req} T_j \quad (P_{FW} > 0) \quad (8.10)$$

$$\Delta A_{Q\max} = \sum_{i=1}^{k_i} \Delta Q_{\max i} T_i \quad (\Delta Q_{\max i} > 0) \quad (8.11)$$

$$\Delta A_{Q\min} = \sum_{l=1}^{k_l} \Delta Q_{\max l} T_l \quad (\Delta Q_{\min l} < 0) \quad (8.12)$$

przy czym indeks i dotyczy okresów roku z deficytem wymaganej generacji mocy biernej, a indeks l okresów z deficytem wymaganego poboru tej mocy.

Odniesienie wielkości „deficytu gotowości” do wartości rocznych wymagań w zakresie generacji lub poboru „energii biernej” (cudzośćów sygnalizuje wątpliwości autora odnośnie sensu fizycznego tego pojęcia) pozwala na całościowe porównanie skuteczności poszczególnych układów elektrycznych farm wiatrowych w zakresie możliwości spełnienia wymagań rozporządzenia UE 2016/631.

$$a_{Q\max} = \frac{\Delta A_{Q\max}}{A_{Q\max}} \cdot 100\% \quad (8.13)$$

$$a_{Q\min} = \frac{\Delta A_{Q\min}}{A_{Q\min}} \cdot 100\% \quad (8.14)$$

Wskaźniki $a_{Q\max}$ i $a_{Q\min}$ dla idealnie dobranych możliwości generacji/poboru mocy biernej farmy powinny mieć wartość zerową. Wartość niezerowa świadczy o braku możliwości spełnienia wymagań rozporządzenia UE 2016/631 przez cały analizowany okres. Wykonano, zatem obliczenia mające na celu optymalny dobór dławika, po stronie 110 kV i ewentualnie baterii kondensatorów po stronie SN, w rozpatrywanej sieci FW. Za funkcję celu, stanowiącą sumę dwóch wskaźników opisanych powyżej, uzależnionych od wektorów $\mathbf{x}$, $\mathbf{y}$, $\mathbf{z}$, przyjęto zależność:

$$F_c(\mathbf{x}, \mathbf{y}, \mathbf{z}) = a_{Q\max} + a_{Q\min} \quad (8.15)$$

gdzie:

$\mathbf{x} = [Q_{Ln}, Q_c]$ – oznacza wartość mocy znamionowej dławika kompensacyjnego 110 kV oraz baterii kondensatorów po stronie SN (wektor zmiennych decyzyjnych),

$\mathbf{y} = [P_{L1}, \dots, P_{Li}, Q_{L1}, \dots, Q_{Li}, P_{Gn1}, \dots, P_{Gnm}]$ – wektor mocy odbieranych oraz mocy generowanych nie podlegających regulacji (wektor zmiennych niezależnych),
 $\mathbf{z} = [U_1, \dots, U_i, \delta_1, \dots, \delta_i]$ – wektor fazorów napięć węzłowych (wektor zmiennych zależnych).

Ograniczenie zmiennych decyzyjnych (wektora $\mathbf{x}$) stanowi:

- wartość mocy biernej dławika kompensacyjnego, zawierająca się w granicach od 0 do 20 Mvar,
- wartość mocy biernej baterii kondensatorów po stronie SN, zawierająca się w granicach od 0 do 10 Mvar (zmienna ma charakter dyskretny – założono, że poszczególne człony baterii stopniowane są co 1 Mvar).

Ograniczenia zmiennych zależnych (wektora $\mathbf{z}$) stanowią:

- dopuszczalne wartości napięć w węzłach (generalnie utrzymywane w zakresie od $0,9U_n$ do $1,1U_n$).

Ograniczenia równościowe $\mathbf{g}(\mathbf{x}, \mathbf{y}, \mathbf{z})$ stanowią:

- równania węzłowe przepływów mocy,

Ograniczenia nierównościowe $\mathbf{h}(\mathbf{x}, \mathbf{y}, \mathbf{z})$ stanowią:

- dopuszczalne obciążalności linii elektroenergetycznych,
- dopuszczalne obciążalności transformatorów.

Obliczenia, według algorytmu AIG, wykonano dla dwóch wariantów:

1. optymalizacja doboru dławika FSR
 - wymagania rozporządzenia UE 2016/631,
 - dotychczasowe wymagania krajowe,
2. optymalizacja doboru dławika VSR oraz baterii kondensatorów po stronie SN
 - wymagania rozporządzenia UE 2016/631,
 - dotychczasowe wymagania krajowe.


W obliczeniach założono 5 strzałów* (w przypadku algorytmu AIG, losowanie kątów korekcyjnych odbywało się przy wykorzystaniu rozkładu normalnego), 5 kukulek* (CS) i 5 ciem* (MFO), oraz maksymalną liczbę iteracji równą 30.

W pierwszym przypadku:

Dobór tylko jednego urządzenia kompensacyjnego – dławika FSR, uzyskano następujące wyniki:


- 1. Wymagania rozporządzenia UE 2016/631** Optymalna wartość mocy znamionowej dławika FSR wynosi 16,5 Mvar przy wskaźniku $a_{Q_{\max}} = 17\%$ i $a_{Q_{\min}} = 8,9\%$. Przykładowy przebieg najlepszych wartości funkcji celu, według algorytmów AIG, CS i MFO przedstawiono poniżej.

* Terminologia zaczerpnięta z literatury związanej z optymalizacją heurystyczną będzie używana w dalszej części monografii.



Rys. 8.9 Przebieg zmienności najlepszych wartości funkcji celu (algorytm AIG, CS, MFO)

2. **Dotychczasowe wymagania krajowe** Optymalna wartość mocy znamionowej dławika FSR wynosi 16,5 Mvar przy wskaźniku $a_{Q_{\max}} = 15,4\%$ i $a_{Q_{\min}} = 0\%$. Przykładowy przebieg najlepszych wartości funkcji celu, według algorytmów AIG, CS i MFO, przedstawiono poniżej.



Rys. 8.10 Przebieg zmienności najlepszych wartości funkcji celu (algorytm AIG, CS, MFO)


Moc optymalna dławika jest taka sama dla obydwu wymagań, co można tłumaczyć tym, że przeważa konieczność wyzerowania przepływów mocy biernej w stanie jałowym.

W drugim przypadku

Dokonano optymalnego doboru dławika VSR oraz baterii kondensatorów po stronie SN tak, aby wyzerować wskaźniki $a_{Q_{\max}}$ i $a_{Q_{\min}}$. Wiąże się to, oczywiście, z odpowiednio wyższymi kosztami inwestycji. Na podstawie obliczeń, uzyskano następujące wyniki:


1. **Wymagania rozporządzenia UE 2016/631** Optymalna wartość mocy znamionowej dławika VSR wynosi 28,5 Mvar (przy zakresie regulacji mocy w przedziale $0,2 \cdot Q_{LN} \div Q_{LN}$). Optymalna wartość baterii kondensatorów po stronie SN wynosi 8 Mvar (stopniowane co 1 Mvar). Wskaźniki $a_{Q_{\max}}$ i $a_{Q_{\min}}$

są równe 0%. Przykładowy przebieg najlepszych wartości funkcji celu, według algorytmów AIG, CS i MFO przedstawiono poniżej.



Rys. 8.11 Przebieg zmienności najlepszych wartości funkcji celu (algorytm AIG, CS, MFO)

2. **Dotychczasowe wymagania krajowe** Optymalna wartość mocy znamionowej dławika FSR wynosi 16,5 Mvar (przy zakresie regulacji mocy w przedziale $0,25 \cdot Q_{LN} \div Q_{LN}$). Wskaźniki $a_{Q_{max}}$ i $a_{Q_{min}}$ są równe 0%. W tym przypadku nie ma konieczności stosowania dodatkowych urządzeń po stronie SN. Przykładowy przebieg najlepszych wartości funkcji celu, według algorytmów AIG, CS i MFO przedstawiono poniżej.



Rys. 8.12 Przebieg zmienności najlepszych wartości funkcji celu (algorytm AIG, CS, MFO)

Uzyskane wyniki potwierdzają wysoką skuteczność algorytmu AIG. Praktycznie w każdym przypadku stosunkowo szybko znajduje rozwiązanie (wystarczy kilka-kilkanaście iteracji).

9. Optymalizacja rozpliwów mocy biernej w systemie elektroenergetycznym

9.1 Wprowadzenie


System elektroenergetyczny charakteryzuje się dużym zapotrzebowaniem na moc bierną indukcyjną. Z punktu widzenia racjonalnego wykorzystania infrastruktury sieciowej korzystne jest wytwarzanie mocy biernej w pobliżu miejsca jej zapotrzebowania. Dzięki temu zmniejsza się obciążenie sieci przepływem tej mocy, a tym samym maleją straty mocy i energii w sieci. Korzystnym następstwem jest też zmniejszenie spadków napięcia, a tym samym podwyższenie poziomów napięcia, szczególnie tam, gdzie jest ono niskie.

W związku z tym, że przepustowość układu jest ograniczona wartością mocy pozornej, zmniejszając przepływ mocy biernej można zwiększyć przesyłaną przez elementy sieciowe moc czynną bez dodatkowych nakładów inwestycyjnych. Zmniejszenie strat mocy czynnej związanych z przepływem mocy biernej powoduje wzrost sprawności przesyłu. Głównym źródłem mocy biernej są generatory synchroniczne w elektrowniach. Pasywnym źródłem mocy biernej są linie elektroenergetyczne, szczególnie linie najwyższych napięć. Innymi źródłami mocy biernej, celowo instalowanymi w wybranych, optymalnych lokalizacjach są baterie kondensatorów oraz kompensatory statyczne typu SVC i STATCOM (oraz kompensatory synchroniczne). Pomimo ogromnego postępu w technice sterowania układami kompensującymi zaliczanymi do urządzeń FACTS, najpopularniejszym i najchętniej stosowanym sztucznym źródłem mocy biernej są kondensatory.

W tej części monografii zostały przedstawione podstawowe problemy związane z optymalizacją rozpliwów mocy biernej przy równoczesnej minimalizacji strat mocy czynnej za pomocą proponowanego algorytmu. Działania te miały na celu poprawę warunków napięciowych systemu elektroenergetycznego, ale przede wszystkim sprawdzenie skuteczności nowej metody heurystycznej. Celem przeprowadzonych obliczeń było także wykazanie, iż odpowiednie sterowanie produkcją mocy biernej w generatorach oraz właściwa regulacja przekładni transformatorów systemowych może przyczynić się do obniżenia strat mocy czynnej w systemie oraz do zapewnienia odpowiednich warunków napięciowych we wszystkich węzłach sieci.

9.2 Opis sieci testowej

Przeanalizowano problem optymalizacji mocy biernej w zmodyfikowanej sieci CIGRE (rys. 9.1), składającej się z 30 węzłów, 36 gałęzi (linii i transformatorów), 33 odbiorów, 8 źródeł (w tym jedno źródło przyłączone jest do węzła bilansującego) oraz dwóch baterii kondensatorów.



Rys. 9.1 Schemat sieci CIGRE

9.3 Obliczenia optymalizacyjne

W niniejszym rozdziale założono, że funkcję celu stanowią będą straty mocy czynnej w sieci elektroenergetycznej, zgodnie ze wzorem [168]:

$$F_c(x, y, z) = \Delta P(x, y, z) \quad (9.1)$$

gdzie:

$\mathbf{x} = [U_{G1}, \dots, U_{Gi}, v_1, \dots, v_j, Q_1, \dots, Q_k]$ – wektor napięć zadanych w węzłach wytwórczych, przekładni transformatorów regulacyjnych (zmienna dyskretna) oraz mocy biernych kompensatorów zainstalowanych w wybranych węzłach sieci (wektor zmiennych decyzyjnych),

$\mathbf{y} = [P_{L1}, \dots, P_{Li}, Q_{L1}, \dots, Q_{Li}, P_{Gn1}, \dots, P_{Gnm}]$ – wektor mocy odbieranych oraz mocy generowanych nie podlegających regulacji (wektor zmiennych niezależnych),

$\mathbf{z} = [U_1, \dots, U_i, \delta_1, \dots, \delta_i]$ – wektor fazorów napięć węzłowych (wektor zmiennych zależnych).

Ograniczenie zmiennych decyzyjnych (wektora $\mathbf{x}$) przedstawiono w tab. 9.1, tab. 9.2, tab. 9.3:

**Tab. 9.1 Lista węzłów wytwórczych z dopuszczalnymi wartościami napięć
(wektor zmiennych decyzyjnych)**

Lp.	Węzeł	U_i		Generator
		U_{imin}	U_{imax}	
-	-	pu	pu	-
1	YB01-G1	0,955	1,118	B01_1-01
2	YB05-G1	0,955	1,114	B05_2-01
3	YB06-G1	0,955	1,114	B06_2-01
4	YB07-G1	0,955	1,114	DO7_2-01
5	YB14-G1	0,955	1,118	B14_1-01
6	YB3H-G1	0,955	1,114	B3H_2-01
7	YB4H-G1	0,95	1,05	B4H_4-01

**Tab. 9.2 Lista transformatorów dopuszczalnymi wartościami przekładni
(wektor zmiennych decyzyjnych)**

Lp.	Gałąź	Węzeł pocz.	Węzeł końc.	v_j	
				v_{jmin}	v_{jmax}
-	-	-	-	pu	pu
1	B4H-A1	B4H411	B4H211	0,9091	1,1111
2	B4H-T1	B4H411	B4L112	0,8929	1,1364

**Tab. 9.3 Lista źródeł mocy biernej wraz z dopuszczalnymi wartościami mocy biernej
(wektor zmiennych decyzyjnych)**

Lp	Węzeł	Nazwa baterii	Q_k	
			Q_{kmin}	Q_{kmax}
-	-	-	Mvar	Mvar
1	B3M511	B3M-C1	-15	15
2	B4M511	B4M-C1	-24,3	24,3

Ograniczenia zmiennych zależnych (wektora z) stanowią:

- dopuszczalne wartości napięć w węzłach (generalnie utrzymywane w zakresie od $0,9U_n$ do $1,1U_n$).

Ograniczenia równościowe $g(x, y, z)$ stanowią:

- równania węzłowe rozływów mocy.

Ograniczenia nierównościowe $h(x, y, z)$ stanowią:

- dopuszczalne obciążalności linii elektroenergetycznych,
- dopuszczalne obciążalności transformatorów.

W obliczeniach założono 15 „strzałów” oraz maksymalną liczbę iteracji równą 1000. Losowanie kątów korekcyjnych odbywało się przy wykorzystaniu rozkładu równomiernego.

Omawiana tematyka była przedmiotem analiza autora w pracy [194].

– optymalizacja stanu bazowego sieci CIGRE

Straty mocy w stanie bazowym wynosiły 52,15 MW. Minimalna wartość funkcji celu, uzyskana za pomocą algorytmu AIG, wynosi 45,31 MW. Dla porównania, najlepsza wartość uzyskana za pomocą metody symulowanego wyżarzania wyniosła 45,7 MW, natomiast za pomocą roju cząstek – 45,45 MW. W poniższych tabelach przedstawiono wyniki optymalizacji (uzyskane za pomocą algorytmu AIG) dla stanu bazowego.

Tab. 9.4 Lista źródeł wraz z optymalnymi wartościami napięć (według algorytmu AIG)

Lp.	Węzeł	Napięcie znamionowe	Napięcie		Napięcie optymalne	Generator	Moc bierna	
			Max.	Min.			Max.	Min.
-	-	kV	pu	pu	pu	-	Mvar	Mvar
1	YB01-G1	10.5	1,118	0,955	1,09	B01_1-01	45	-10
2	YB05-G1	22	1,114	0,955	1,114	B05_2-01	190	-20,8
3	YB06-G1	22	1,114	0,955	1,114	B06_2-01	190	-20,8
4	YB07-G1	15.8	1,114	0,955	1,114	DO7_2-01	112,8	-21,9
5	YB14-G1	13.8	1,118	0,955	1,104	B14_1-01	86,8	-14,9
6	YB3H-G1	22	1,114	0,955	1,1	B3H_2-01	190	-20,8
7	YB4H-G1	27	1,05	0,95	1,04	B4H_4-01	661,8	-371


Tab. 9.5 Lista transformatorów wraz z optymalnymi wartościami przekładni (według algorytmu AIG)

Lp.	Gałąź	Węzeł pocz.	Węzeł końc.	Przekładnia		Przekładnia optymalna
				max	min	
-	-	-	-	pu	pu	pu
1	B4H-A1	B4H411	B4H211	1,1111	0,9091	0,9091
2	B4H-T1	B4H411	B4L112	1,1364	0,8929	0,893

Tab. 9.6 Lista źródeł mocy biernej wraz z optymalnymi wartościami (według algorytmu AIG)

Lp	Węzeł	Nazwa baterii	Moc bierna		Moc bierna optymalna
			max	min	
-	-	-	Mvar	Mvar	Mvar
1	B3M511	B3M-C1	15	-15	11,67
2	B4M511	B4M-C1	24,3	-24,3	10,73

Przykładowy przebieg zmienności najlepszych wartości funkcji celu, przedstawiono na rys. 9.2.



Rys. 9.2 Przykładowy przebieg procesu optymalizacji (algorytm AIG)

– optymalna lokalizacja dodatkowych źródeł mocy biernej

Dodatkowe źródła mocy biernej w postaci baterii kondensatorów czy kompensatorów mogą być instalowane w różnych miejscach sieci w zależności od potrzeb. Do metod pozwalających wstępnie określić miejsca lokalizacji nowych źródeł mocy biernej można zaliczyć metody rankingowe oraz metodę przeszukiwania całej sieci.

Metoda badania całej sieci polega na założeniu istnienia nowych źródeł mocy biernej we wszystkich węzłach sieci bądź też węzłach wybranych, a następnie optymalizacji pod kątem wybranej funkcji celu (w opracowaniu za funkcję celu przyjmowano straty mocy czynnej w całej sieci). Wyniki obliczeń optymalizacyjnych według tej metody pozwalają wytypować miejsca, w których potrzeba zainstalowania dodatkowych źródeł mocy biernej jest największa. Do obliczeń założono, że nowe źródła mogą być instalowane we wszystkich węzłach oprócz wytwórczych (tab. 9.7). Wyniki obliczeń dla tej metody zostały przedstawione w tab. 9.8–tab. 9.10.


Tab. 9.7 Lista węzłów sieci testowej CIGRE, w których planowane jest przyłączenie nowych źródeł mocy biernej

Lp.	Kod węzła	Napięcie znamionowe	Napięcie maksymalne	Napięcie minimalne
-	-	kV	pu	pu
1	B02211	220	1,114	0,955
2	B08211	220	1,114	0,955
3	B09211	220	1,114	0,95
4	B10211	220	1,114	0,955
5	B3M511	16	1,1	0,906
6	B4H211	220	1,114	0,955
7	B11112	110	1,118	0,955
8	B12112	110	1,118	0,955
9	B13112	110	1,118	0,955
10	B15112	110	1,118	0,955
11	B3L112	110	1,118	0,955
12	B4L112	110	1,118	0,955
13	B4M511	32	1,1	0,906

Tab. 9.8 Wyniki poszukiwania nowych lokalizacji źródeł mocy biernej metodą przeszukiwania całej sieci przy wykorzystaniu algorytmu AIG

Lp.	Kod węzła	Napięcie znamionowe	Optymalna wartość mocy biernej
-	-	kV	Mvar
1	B02211	220	0,47
2	B08211	220	98,26
3	B09211	220	106,44
4	B10211	220	130,65
5	B3M511	16	0,267
6	B4H211	220	80,5
7	B11112	110	-4,25
8	B12112	110	-6,48
9	B13112	110	-6,64
10	B15112	110	15,21
11	B3L112	110	10,05
12	B4L112	110	37,03
13	B4M511	32	1

Na podstawie wyników uzyskanych za pomocą algorytmu AIG stwierdzono, że nowe źródła mocy biernej powinny zostać zainstalowane w węzłach B08211, B09211, B10211, B4L112, B4H112. Przy wyborze lokalizacji kierowano się największymi wartościami mocy biernej. Straty mocy czynnej w sieci wyniosły po optymalizacji 36,5 MW (w stanie bazowym 52,15 MW). Przykładowy przebieg zmienności najlepszych wartości funkcji celu, przedstawiono na rys. 9.3.



Rys. 9.3 Przebieg zmienności najlepszych wartości funkcji celu (według algorytmu AIG)

Dla porównania, poniżej przedstawiono wyniki uzyskane za pomocą metody symulowanego wyżarzania i roju cząstek.

Tab. 9.9 Wyniki poszukiwania nowych lokalizacji źródeł mocy biernej metodą przeszukiwania całej sieci przy wykorzystaniu algorytmu symulowanego wyżarzania (SA)

Lp.	Kod węzła	Napięcie znamionowe	Optymalna wartość mocy biernej
-	-	kV	Mvar
1	B02211	220	21,3
2	B08211	220	14,2
3	B09211	220	179
4	B10211	220	125,8
5	B3M511	16	12,3
6	B4H211	220	124
7	B11112	110	30
8	B12112	110	-26,7
9	B13112	110	83,4
10	B15112	110	-1,7
11	B3L112	110	-125
12	B4L112	110	128
13	B4M511	32	1,12

Na podstawie wyników uzyskanych metodą symulowanego wyżarzania (SA) stwierdzono, że nowe źródła mocy biernej powinny zostać zainstalowane w węzłach B09211, B10211, B13112, B4L112, B3L112 i B4H211. Przy wyborze lokalizacji kierowano się największymi wartościami mocy biernej. Straty mocy czynnej w sieci wyniosły po optymalizacji 36,7 MW (w stanie bazowym 52,15 MW).

Tab. 9.10 Wyniki poszukiwania nowych lokalizacji źródeł mocy biernej metodą przeszukiwania całej sieci przy wykorzystaniu roju cząstek (PSO)

Lp.	Kod węzła	Napięcie znamionowe	Optymalna wartość mocy biernej
-	-	kV	Mvar
1	B02211	220	-2
2	B08211	220	80,5
3	B09211	220	158,4
4	B10211	220	151,1
5	B3M511	16	-12,8
6	B4H211	220	18,7
7	B11112	110	24
8	B12112	110	19,4
9	B13112	110	40,1
10	B15112	110	12
11	B3L112	110	4,7
12	B4L112	110	137
13	B4M511	32	-7,6

Na podstawie wyników uzyskanych metodą roju cząstek stwierdzono, że nowe źródła mocy biernej powinny zostać zainstalowane w węzłach B08211, B09211, B10211, B13112, B4L112. Straty mocy czynnej w sieci wyniosły po optymalizacji 36,3 MW (w stanie bazowym 52,15 MW).

Metoda rankingowa polega na rozpatrywaniu różnych kryteriów pozwalających wytypować miejsca lokalizacji nowych źródeł mocy biernej. Do obliczeń przy użyciu sieci testowej CIGRE brano pod uwagę cztery kryteria:

- **Kryterium stabilnościowe V-Q**, które polega na tym, że w kolejnych krokach zakłada się niewielkie obniżenie napięcia w wybranym węźle i dla takiego stanu, korzystając z programu obliczania rozptyłu mocy, wyznacza się moc bierną w tym węźle, potrzebną dla utrzymania założonego napięcia. Jeżeli obniżeniu napięcia węzłowego odpowiada obniżenie się mocy biernej węzła, uznaje się, że sieć pracuje stabilnie. Jeżeli obniżeniu napięcia węzłowego w kolejnych krokach nie będzie już odpowiadać obniżanie się, a wzrost mocy biernej węzła, uznaje się, że

sić pracuje niestabilnie. Napięcie, przy którym przyrost mocy biernej zmienił znak na przeciwny nazywa się „napięciem krytycznym”, a moc bierną węzła, przy której to nastąpiło, nazywa się „mocą graniczną”. W tab. 9.11 przedstawiono wyniki obliczeń dla niniejszego kryterium. Na ich podstawie można stwierdzić, że nowe źródła mocy biernej powinny zostać zainstalowane w węzłach B08211, B09211, B10211, czyli tam gdzie wartość $\frac{dQ}{dU}$ jest najmniejsza. Oznacza to, że procentowa zmiana napięcia w tych węzłach jest największa.

Tab. 9.11 Wyniki poszukiwania nowych lokalizacji źródeł mocy biernej według kryterium $\frac{dQ}{dU}$

Nazwa węzła	Moc bierna generowana przed	Napięcie przed	Moc bierna graniczna	Napięcie graniczne	dQ/dU
-	-	kV	Mvar	kV	Mvar/kV
B02211	336.503	253.0	-458.083	193.6	7.712
B08211	330.996	253.0	-57.150	200.2	1.082
B09211	411.326	253.0	-60.436	165.0	0.687
B10211	291.378	253.0	-143.837	143.0	1.308
B4H211	706.830	253.0	-188.228	211.2	4.503
B11112	648.348	126.5	197.661	96.8	6.655
B12112	364.740	126.5	-195.138	97.9	6.823
B13112	313.026	126.5	-169.909	96.8	5.721
B15112	342.376	126.5	-189.192	95.7	6.143
B3L112	442.201	126.5	-173.311	100.1	6.565
B4L112	635.073	126.5	-213.079	102.3	8.805

- **Kryterium stabilnościowe P-V**, które polega na tym, że bada się możliwości poboru mocy czynnej w funkcji napięcia w węźle. Krzywe P-V wyznacza się dla wybranych węzłów sieci również metodą „krok po kroku”. W kolejnych krokach zakłada się niewielkie dociążenie węzła mocą czynną i, licząc rozływ mocy, określa się napięcie w tym węźle. Proces kończy się, gdy obliczenia rozływów mocy są rozbieżne, co oznacza, że w danym punkcie dochodzi do utraty stabilności w sieci. W tab. 9.12 przedstawiono wyniki obliczeń dla niniejszego kryterium. Na ich podstawie można stwierdzić, że nowe źródła mocy biernej powinny zostać zainstalowane w węzłach B09211, B10211, B11112, czyli tam gdzie wartość $\frac{dU}{dP}$ jest największa. Oznacza to, że procentowa zmiana napięcia w tych węzłach jest największa.

Tab. 9.12 Wyniki poszukiwania nowych lokalizacji źródeł mocy biernej według kryterium $\frac{dU}{dP}$

Nazwa węzła	Moc czynna odbierana przed	Moc bierna	Napięcie przed	Przyrost mocy czynnej odbieranej po	Napięcie po	dU/dP
-	MW	Mvar	kV	MW	kV	kV/MW
B02211	12	7	233.4	1273	209.3	0.019
B08211	210	85	215.3	255	211.4	0.015
B09211	440	180	192.8	109	179.8	0.119
B10211	310	160	202.4	222	163.6	0.175
B3M511	0	0	15.8	253	13.2	0.011
B4H211	276	105	228.3	792	222.6	0.007
B11112	50	19	113.1	353	99.3	0.039
B12112	25	9	113.4	527	106.1	0.014
B13112	35	13	114.3	445	105.9	0.019
B15112	40	15	112.4	479	103.7	0.018
B3L112	50	19	114.3	497	107.6	0.013
B4L112	112	42.7	112.9	665	108.4	0.007
B4M511	0	0	33.4	400	30.2	0.008

- **Kryterium $\frac{dU}{dQ}$** – które polega na zwiększaniu poboru mocy biernej

w wybranych węzłach sieci i wyznaczaniu spadku napięcia z tym związanego. Węzły, w których spadek napięcia jest największy kwalifikują się do zainstalowania tam źródeł mocy biernej. W tab. 9.13 przedstawiono wyniki obliczeń dla niniejszego kryterium. Na ich podstawie można stwierdzić, że nowe źródła mocy biernej powinny zostać zainstalowane w węzłach B08211, B09211, B10211, B11112, czyli tam gdzie wartość $\frac{dU}{dQ}$ jest największa.

Oznacza to, że procentowa zmiana napięcia w tych węzłach jest największa.

Tab. 9.13 Wyniki poszukiwania nowych lokalizacji źródeł mocy biernej według kryterium $\frac{dU}{dQ}$

Nazwa węzła	Moc czynna odbierana	Moc bierna odbierana przed	Napięcie przed	Moc bierna odbierana po	Napięcie po	dU/dQ
-	MW	Mvar	kV	Mvar	kV	kV/Mvar
B02211	12	7	233.4	52	230.3	0.069
B08211	210	85	215.3	130	211.0	0.096
B09211	440	180	192.8	225	177.8	0.334
B10211	310	160	202.4	205	191.0	0.255
B3M511	0	0	15.8	45	14.4	0.031
B4H211	276	105	228.3	150	226.4	0.042
B11112	50	19	113.1	64	108.4	0.103
B12112	25	9	113.4	54	111.3	0.047
B13112	35	13	114.3	58	111.3	0.065
B15112	40	15	112.4	60	109.8	0.058
B3L112	50	19	114.3	64	111.9	0.052
B4L112	112	42.7	112.9	87.7	111.7	0.026
B4M511	0	0	33.4	45	32.0	0.031

- **Kryterium** $\frac{d(\Delta P)}{dQ}$ - które polega na zwiększaniu poboru mocy biernej

w wybranych węzłach sieci i wyznaczaniu procentowej różnicy strat mocy czynnej w całej sieci w odniesieniu do strat mocy czynnej w stanie bazowym. Węzły, w których powiększenie poboru mocy biernej spowoduje największe procentowe zmiany strat mocy czynnej w sieci kwalifikują się do zainstalowania tam źródeł mocy biernej. W tab. 9.14 przedstawiono wyniki obliczeń dla niniejszego kryterium. Na ich podstawie można stwierdzić, że nowe źródła mocy biernej powinny zostać zainstalowane w węzłach B08211, B09211, B10211, B11112, czyli tam gdzie wartość $\frac{d(\Delta P)}{dQ}$ jest największa. Oznacza to, że

procentowa zmiana strat mocy w sieci po zwiększeniu mocy biernej pobieranej w tych węzłach jest największa.

Tab. 9.14 Wyniki poszukiwania nowych lokalizacji źródeł mocy biernej według

kryterium $\frac{d(\Delta P)}{dQ}$

Nazwa węzła	Moc czynna odbierana	Moc bierna odbierana przed	Straty przed	Moc bierna odbierana po	Straty po	d(ΔP)/dQ
-	MW	Mvar	MW	Mvar	MW	MW/Mvar
B02211	12	7	52.083	52	52.541	0.010
B08211	210	85	52.083	130	53.601	0.034
B09211	440	180	52.083	225	57.619	0.123
B10211	310	160	52.083	205	54.752	0.059
B3M511	0	0	52.083	45	52.938	0.019
B4H211	276	105	52.083	150	52.781	0.016
B11112	50	19	52.083	64	53.115	0.023
B12112	25	9	52.083	54	52.785	0.016
B13112	35	13	52.083	58	52.971	0.020
B15112	40	15	52.083	60	52.909	0.018
B3L112	50	19	52.083	64	52.998	0.020
B4L112	112	42.7	52.083	87.7	52.748	0.015
B4M511	0	0	52.083	45	52.778	0.015

- Kryterium $\frac{dU}{dQ}$ i $\frac{d(\Delta P)}{dQ}$ jednocześnie, które polega na tym, że bada się, w których węzłach występuje jednocześnie największa podatność napięcia i strat mocy w sieci na powiększanie poboru mocy biernej. W tab. 9.15 przedstawiono wyniki obliczeń dla niniejszego kryterium. Na ich podstawie można stwierdzić, że nowe źródła mocy biernej powinny zostać zainstalowane w węzłach B08211, B09211, B10211, B11112 czyli tam, gdzie wartości $\frac{dU}{dQ}$ i $\frac{d(\Delta P)}{dQ}$ są największe. Oznacza to, że procentowa zmiana napięcia w tych węzłach jest największa oraz że procentowa zmiana strat mocy w sieci po zwiększeniu mocy biernej pobieranej w tych węzłach jest największa.

Tab. 9.15 Wyniki poszukiwania nowych lokalizacji źródeł mocy biernej według kryterium

$$\frac{dU}{dQ} \text{ i } \frac{d(\Delta P)}{dQ} \text{ jednocześnie}$$

Nazwa węzła	Moc bierna odbierana przed	Straty przed	Moc bierna odbierana po	Straty po	dU/dQ	dP/dQ
-	Mvar	MW	Mvar	MW	kV/Mvar	MW/Mvar
B02211	7	52.083	52	52.541	0.069	0.010
B08211	85	52.083	130	53.601	0.096	0.034
B09211	180	52.083	225	57.619	0.334	0.123
B10211	160	52.083	205	54.752	0.255	0.059
B3M511	0	52.083	45	52.938	0.031	0.019
B4H211	105	52.083	150	52.781	0.042	0.016
B11112	19	52.083	64	53.115	0.103	0.023
B12112	9	52.083	54	52.785	0.047	0.016
B13112	13	52.083	58	52.971	0.065	0.020
B15112	15	52.083	60	52.909	0.058	0.018
B3L112	19	52.083	64	52.998	0.052	0.020
B4L112	42.7	52.083	87.7	52.748	0.026	0.015
B4M511	0	52.083	45	52.778	0.031	0.015

Biorąc pod uwagę wyniki obliczeń na podstawie wszystkich kryteriów metody rankingowej badania całej sieci przyjęto, że nowe źródła mocy biernej przyłączone będą do węzłów: B08211, B09211, B10211, B11112, B13112, B3L112, B4L112, B4H211. Natomiast wartości mocy w istniejących bateriach kondensatorów w węzłach B3M511 i B4M511 pozostawiono na poziomie takim jak w stanie bazowym. Wyniki optymalizacji, z uwzględnieniem nowych źródeł mocy biernej, przedstawione zostały poniżej.

Minimalna wartość funkcji celu uzyskana za pomocą algorytmu AIG wynosi 36,2 MW (w stanie bazowym 52,15 MW). W tab. 9.16–tab. 9.18 przedstawiono wyniki obliczeń dla algorytmu AIG.

Tab. 9.16 Lista źródeł wraz z optymalnymi wartościami napięć

Lp.	Węzeł	Napięcie znamionowe	Napięcie		Napięcie optymalne
			Max.	Min.	pu
-	-	kV	pu	pu	
1	YB01-G1	10,5	1,118	0,955	1,08
2	YB05-G1	22	1,114	0,955	1,114
3	YB06-G1	22	1,114	0,955	1,114
4	YB07-G1	15,8	1,114	0,955	1,114
5	YB14-G1	13,8	1,118	0,955	1,09
6	YB3H-G1	22	1,114	0,955	1,114
7	YB4H-G1	27	1,05	0,95	1,012


Tab. 9.17 Lista transformatorów wraz z optymalnymi wartościami przekładni

Lp.	Gałąź	Węzeł pocz.	Węzeł końc.	Przekładnia		Przekładnia optymalna
				max	min	pu
-	-	-	-	pu	pu	
1	B4H-A1	B4H411	B4H211	1,1111	0,9091	0,9091
2	B4H-T1	B4H411	B4L112	1,1364	0,8929	0,922

Tab. 9.18 Lista źródeł mocy biernej wraz z optymalnymi wartościami

Lp	Węzeł	Nazwa baterii	Napięcie znamionowe	Moc bierna optymalna
			kV	Mvar
1	B08211	B08-C1	220	79
2	B09211	B09-C1	220	161
3	B10211	B10-C1	220	142
4	B11112	B11-C1	110	19
5	B13112	B13-C1	110	34
6	B3L112	B3L-C1	110	-50
7	B4L112	B4L-C1	110	-27
8	B4H211	B4H-C1	220	146

Przykładowy przebieg zmienności najlepszych wartości funkcji celu, przedstawiono na rys. 9.4.



Rys. 9.4 Przebieg zmienności najlepszych wartości funkcji celu (według algorytmu AIG)

Dla porównania, w tab. 9.19–tab. 9.21 przedstawiono wyniki obliczeń dla algorytmu symulowanego wyłazania. Minimalna wartość funkcji celu wynosi 36,28 MW (w stanie bazowym 52,15 MW).

Tab. 9.19 Lista źródeł wraz z optymalnymi wartościami napięć

Lp.	Węzeł	Napięcie znamionowe	Napięcie		Napięcie optymalne
			Max.	Min.	
-	-	kV	pu	pu	pu
1	YB01-G1	10,5	1,118	0,955	1,091
2	YB05-G1	22	1,114	0,955	1,114
3	YB06-G1	22	1,114	0,955	1,114
4	YB07-G1	15,8	1,114	0,955	1,112
5	YB14-G1	13,8	1,118	0,955	1,104
6	YB3H-G1	22	1,114	0,955	1,112
7	YB4H-G1	27	1,05	0,95	1,04

Tab. 9.20 Lista transformatorów wraz z optymalnymi wartościami przekładni

Lp.	Gałąź	Węzeł pocz.	Węzeł końc.	Przekładnia		Przekładnia optymalna
				max	min	pu
-	-	-	-	pu	pu	
1	B4H-A1	B4H411	B4H211	1,1111	0,9091	0,90931
2	B4H-T1	B4H411	B4L112	1,1364	0,8929	0,92241

Tab. 9.21 Lista źródeł mocy biernej wraz z optymalnymi wartościami

Lp	Węzeł	Nazwa baterii	Napięcie znamionowe	Moc bierna optymalna
			kV	Mvar
-	-	-	-	-
1	B08211	B08-C1	220	70,8
2	B09211	B09-C1	220	168,6
3	B10211	B10-C1	220	135,2
4	B11112	B11-C1	110	18,6
5	B13112	B13-C1	110	25,5
6	B3L112	B3L-C1	110	-76,6
7	B4L112	B4L-C1	110	-5,3
8	B4H211	B4H-C1	220	144,0

Dla porównania w tab. 9.22–tab. 9.24 przedstawiono wyniki obliczeń dla algorytmu roju cząstek. Minimalna wartość funkcji celu wynosi 36,11 MW (w stanie bazowym 52,15 MW).

Tab. 9.22 Lista źródeł wraz z optymalnymi wartościami napięć

Lp.	Węzeł	Napięcie znamionowe	Napięcie		Napięcie optymalne
			Max.	Min.	pu
-	-	kV	pu	pu	
1	YB01-G1	10,5	1,118	0,955	1,077
2	YB05-G1	22	1,114	0,955	1,114
3	YB06-G1	22	1,114	0,955	1,114
4	YB07-G1	15,8	1,114	0,955	1,114
5	YB14-G1	13,8	1,118	0,955	1,084
6	YB3H-G1	22	1,114	0,955	1,113
7	YB4H-G1	27	1,05	0,95	1,010

Tab. 9.23 Lista transformatorów wraz z optymalnymi wartościami przekładni

Lp.	Gałąź	Węzeł pocz.	Węzeł końc.	Przekładnia		Przekładnia optymalna
				max	min	pu
-	-	-	-	pu	pu	
1	B4H-A1	B4H411	B4H211	1,1111	0,9091	0,9102
2	B4H-T1	B4H411	B4L112	1,1364	0,8929	0,9161

Tab. 9.24 Lista źródeł mocy biernej wraz z optymalnymi wartościami

Lp	Węzeł	Nazwa baterii	Napięcie znamionowe	Moc bierna optymalna
			kV	Mvar
1	B08211	B08-C1	220	77,9
2	B09211	B09-C1	220	160,1
3	B10211	B10-C1	220	143,7
4	B11112	B11-C1	110	20,0
5	B13112	B13-C1	110	32,9
6	B3L112	B3L-C1	110	-52,8
7	B4L112	B4L-C1	110	-26,4
8	B4H211	B4H-C1	220	142,0

Wyniki uzyskane, przy pomocy algorytmu AIG, są porównywalne (a w niektórych przypadkach lepsze) od wyników osiągniętych metodami roju cząstek (PSO) i symulowanego wyżarzania (SA). Tym samym algorytm ten może być z powodzeniem stosowany do rozwiązywania zagadnienia minimalizacji strat mocy, jako szczególnie istotnego optymalizacji pracy systemu elektroenergetycznego.

10. Minimalizacja różnicy kątów fazorów napięcia przy załączaniu linii elektroenergetycznych

10.1 Wprowadzenie

Ruchowe albo awaryjne odstawienie linii przesyłowej lub transformatora pociąga za sobą konieczność ich załączenia i przywrócenia zdolności przesyłowej sieci. Silne obciążenie sieci przesyłowej w stanie wyłączenia elementu sieci powoduje znaczne różnice napięć na otwartych biegunach wyłącznika, które mogą być duże zarówno pod względem modułu jak i fazy. Zamknięcie wyłącznika przy dużej wartości kąta załączenia może wywołać duży udar prądowy groźny dla elementów SEE. Należy podjąć zatem działania mające na celu ograniczenie udaru prądowego w warunkach załączania elementów sieci przesyłowej.

Dla ograniczenia udarów prądowych stosuje się urządzenia synchrocheck do kontroli warunków załączania elementów sieci przesyłowej. Urządzenia te sprawdzają: różnicę napięć, różnicę argumentów napięć, różnicę częstotliwości. Gdy warunki panujące w SEE nie zezwalają na zamknięcie wyłącznika operatorzy SEE muszą podjąć działania zmierzające do takiej zmiany stanu SEE by załączenie danego elementu sieci było możliwe i bezpieczne. Nazywa się to redukcją kąta załączenia (ang. *standing phase angle reduction*). Załączenie będzie możliwe dopiero po zredukowaniu różnicy kątów napięć na biegunach wyłącznika do wartości dopuszczalnej poprzez:


- odpowiednią zmianę rozdziału obciążenia wybranych węzłów wytwórczych, (ang. *generation rescheduling*) przy zadanym obciążeniu odbiorów,
- odciążenie wybranych węzłów odbiorczych (ang. *load shedding*).

Najpierw rozważa się redukcję kąta załączenia poprzez zmianę rozdziału obciążeń między węzły wytwórcze (z uwagi na koszt niedostarczenia energii elektrycznej). Gdy ten sposób redukcji kąta obciążenia nie daje spodziewanych wyników, analizuje się odciążenie sieci przez wyłączenie części odbiorów. Zmiana rozdziału obciążeń jest zabiegiem chwilowym i po załączeniu linii można przywrócić poprzedni stan. Decyzję o sposobie zmiany rozdziału obciążenia operator SEE może podjąć w oparciu o intuicję inżynierską lub odpowiednie obliczenia optymalizacyjne. Działanie oparte tylko na intuicji może nie być trafne i może przyczynić się do powstania awarii systemowej polegającej na kaskadowym wyłączaniu przeciążonych elementów sieci. W omawianej sytuacji szybkość i trafność decyzji są bardzo cenne dla przeciwdziałania awarii systemowej. Wskazane jest więc by wśród licznych programów komputerowych wspomagających pracę operatora SEE były też algorytmy określające wymagany sposób zmiany rozdziału obciążenia prowadzący w sposób optymalny do zadanej redukcji różnicy napięć na biegunach wyłącznika.

Ze względu na tymczasowość poszukiwanego stanu SEE, straty sieciowe nie są istotne. Ważne jest, aby skutecznie i bezpiecznie zminimalizować różnice kątów. Wyraz „skutecznie” oznacza jak najmniejsze zmiany obciążeń dla uzyskania wymaganej redukcji kąta załączenia. Powinny zostać wybrane te źródła lub odbiory, które w największym stopniu wpływają na różnicę napięć na biegunach wyłącznika. Wyraz „bezpiecznie” oznacza brak zagrożenia pewnością pracy SEE. Rozpatrywana tematyka szeroko opisana została m. in. pracach [195, 196, 197, 198, 199, 200, 201, 202, 203, 204, 244].

10.2 Opis sieci testowej

Rozważany problem analizowany był na zmodyfikowanej sieci testowej IEEE 118-Bus, przedstawionej na rys. 10.1. Różnica między siecią pierwotną a zmodyfikowaną polega głównie na dodaniu sieci przesyłowej.



Rys. 10.1 Zmodyfikowana sieć testowa IEEE 118-Bus [215]

Rozpatrywana sieć składa się z 118 węzłów o napięciach 230 kV i 500 kV, 178 linii, 54 źródeł, przy czym do analizy wytypowano 11.

Załączanie dwóch linii przesyłowych, oznaczonych na rys. 10.1 jako „Linia 1” i „Linia 2”, wiązało się z koniecznością redukcji kąta załączenia. W przypadku Linii 1, kąt ten, przy otwartym wyłączniku wynosił 52° , natomiast w przypadku Linii 2 – 48° .

10.3 Obliczenia

Funkcją celu jest różnica kątów w dwóch wybranych węzłach sieci. Fakt, że węzły te są biegunami otwartego wyłącznika nie ma tu znaczenia. Jeżeli założymy, że węzłami rozpatrywanymi są węzły i oraz j to funkcja celu przyjmie postać:

$$F_c(\mathbf{x}, \mathbf{y}, \mathbf{z}) = |\delta_{ij}(\mathbf{x}, \mathbf{y}, \mathbf{z}) - \delta_{ij\text{wym}}| \quad (10.1)$$

gdzie:

$\mathbf{x} = [P_{G1}, \dots, P_{Gm}]$ – wektor mocy czynnych generowanych przez rozpatrywane źródła wytwórcze (wektor zmiennych decyzyjnych),

$\mathbf{y} = [P_{L1}, \dots, P_{Li}, Q_{L1}, \dots, Q_{Li}, P_{Gn1}, \dots, P_{Gnm}]$ – wektor mocy odbieranych oraz mocy generowanych nie podlegających regulacji (wektor zmiennych niezależnych),

$\mathbf{z} = [U_1, \dots, U_i, \delta_1, \dots, \delta_i]$ – wektor fazorów napięć węzłowych (wektor zmiennych zależnych).

δ_{ij} – różnica kątów fazorów napięć pomiędzy węzłami i oraz j ,

$\delta_{ij\text{wym}}$ – wymagana różnica kątów fazorów napięć pomiędzy węzłami i oraz j .

Ograniczenie zmiennych decyzyjnych (wektora $\mathbf{x}$) przedstawiono w tab. 10.1.

Tab. 10.1 Ograniczenia zmiennych decyzyjnych (wektora $\mathbf{x}$)

Lp.	$P_{Gj\text{min}}$ MW	$P_{Gj\text{max}}$ MW
1	100	500
2	100	500
3	100	500
4	100	500
5	100	500
6	100	600
7	100	600
8	100	700
9	100	700
10	100	700
11	100	600

Ograniczenia zmiennych zależnych (wektora $\mathbf{z}$) stanowią:

- dopuszczalne wartości napięć w węzłach (generalnie utrzymywane w zakresie od $0,9U_n$ do $1,1U_n$).

Ograniczenia równościowe $\mathbf{g}(\mathbf{x}, \mathbf{y}, \mathbf{z})$ stanowią:

- równania węzłowe rozplływów mocy,


Ograniczenia nierównościowe $\mathbf{h}(\mathbf{x}, \mathbf{y}, \mathbf{z})$ stanowią:

- dopuszczalne obciążalności linii elektroenergetycznych,
- dopuszczalne obciążalności transformatorów.

W przypadku algorytmu AIG, w obliczeniach założono 10 strzałów. Losowanie kątów korekcyjnych odbywało się przy wykorzystaniu rozkładu normalnego. Dla algorytmu CS założono 10 kukulek, natomiast dla MFO – 10 ciem oraz maksymalną liczbę iteracji równą 100.


Dla sprawdzenia skuteczności algorytmu AIG założono, że $\delta_{ij\text{wym}}$ będzie równa 0° . W obydwu przypadkach linii (Linia 1 i Linia 2) udało się zredukować różnice kątów do 0° poprzez tylko i wyłącznie zmianę rozkładu generacji w wybranych źródłach wytwórczych.

Poniżej przedstawiono zmienność najlepszych wartości funkcji celu dla algorytmów AIG, CS i MFO. Jako pierwszą rozpatrzono Linię 1. Okazało się, że do redukcji kąta załączenia do wartości 0° należało zmieniać moce generowane w 11 źródłach wytwórczych.



Rys. 10.2 Przebieg zmienności najlepszych wartości funkcji celu, dla redukcji kąta załączenia Lini 1 (algorytm AIG, CS, MFO)

Jako drugą rozpatrzono Linię 2. Okazało się, że do redukcji kąta załączenia do wartości 0° należało zmieniać moce generowane w 10 źródłach wytwórczych. W obliczeniach założono 10 strzałów (AIG), 10 kukulek (CS), 10 ciem (MFO).




Rys. 10.3 Przebieg zmienności najlepszych wartości funkcji celu, dla redukcji kąta załączenia Linii 2 (algorytm AIG, CS, MFO)

Przedstawiony w niniejszym podpunkcie problem został skutecznie rozwiązany za pomocą proponowanego algorytmu AIG. Wyniki obliczeń porównano z dwiema innymi metodami heurystycznymi (CS i MFO).

Należy zwrócić uwagę na fakt, że szukana zmiana rozkładu obciążeń źródeł jest chwilowa i prowadzi do zmniejszenia różnicy napięcia na biegunach wyłącznika w chwili załączenia. Trzeba również podkreślić, że redukcja kąta załączenia za pomocą zmiany rozdziału obciążeń może wymagać znacznych zmian obciążenia zespołów wytwórczych. Z tego względu należy unikać zbyt zaniżonych nastawień dopuszczalnej wartości kąta załączenia w urządzeniach synchrocheck.


W literaturze [244] podawane są wartości nastawcze urządzeń synchrocheck znacznie się różniące od siebie. Największe różnice dotyczą dopuszczalnego kąta załączenia (rozrzut dopuszczalnych wartości, w zależności od usytuowania wyłącznika, jest duży – od 20° do 60°). W kolejnym kroku (wariancie) obliczeń przyjęto, że dopuszczalna różnica kątów wynosi 20° i dla tej wartości wykonano obliczenia.

Przy załączaniu **Linii 1** okazało się, że do regulacji wystarczą dwa źródła o bazowych mocach generowanych równych odpowiednio 500 MW i 450 MW. Aby osiągnąć wymaganą redukcję kąta załączenia należy zmienić rozkład generacji na 348 MW i 219 MW. Przebieg zmienności najlepszych wartości funkcji celu dla algorytmów AIG, CS i MFO przedstawiono poniżej.



Rys. 10.4 Przebieg zmienności najlepszych wartości funkcji celu, dla redukcji kąta załączenia Linii 1 (algorytm AIG, CS, MFO)

Przy załączaniu **Linii 2**, okazało się, że do regulacji wystarczą trzy źródła o bazowych mocach generowanych, równych odpowiednio 220 MW, 100 MW i 390 MW. Aby osiągnąć wymaganą redukcję kąta załączenia należy zmienić rozkład generacji na 122 MW, 127 MW i 486 MW. Przebieg zmienności najlepszych wartości funkcji celu dla algorytmów AIG, CS i MFO przedstawiono poniżej.



Rys. 10.5 Przebieg zmienności najlepszych wartości funkcji celu, dla redukcji kąta załączenia Linii 2 (algorytm AIG, CS, MFO)

Wyniki potwierdziły, że proponowany algorytm AIG może być z powodzeniem stosowany także do rozwiązywania zagadnień poruszanych w niniejszym rozdziale.

11. Optymalny dobór parametrów charakterystyk $P(U)$ i $Q(U)$ falowników instalacji fotowoltaicznych


11.1 Wprowadzenie

Tematyka niniejszego podpunktu dotyczy mikroinstalacji fotowoltaicznych przyłączanych do sieci niskiego napięcia. Autor zajmował się tą tematyką w pracach [143, 145, 151, 152, 153, 156, 158, 159, 165].


Instalowanie w sieciach niskiego napięcia dużej liczby mikroinstalacji PV (w obrębie jednej stacji transformatorowej – rys. 11.1) może doprowadzić do niekorzystnego wzrostu napięcia ponad wartość dopuszczalną (440 V lub 230 V). Zaradzić temu można na kilka sposobów:

- poprzez dopasowanie przekładni transformatora SN/nn kV do aktualnego stanu generacji PV,
- poprzez wykorzystanie możliwości regulacji mocy biernej i czynnej źródeł PV,
- poprzez wyłączanie niezbędnej liczby źródeł,
- poprzez zastosowanie dedykowanego, szeregowego transformatora specjalnego zwiększającego reaktancję linii w warunkach narastania napięcia, przy równoczesnym poborze mocy biernej przez mikroinstalacje (układy te noszą generalnie nazwę LVR – *Line Voltage Regulator*, na przykład urządzenie o nazwie firmowej AEG – Thyrobox, podobne urządzenia firmy ABB oraz Schneider Electric),
- drogą modernizacji sieci (wymiana przewodów i transformatora).


Spośród kilku sposobów ograniczania wartości napięcia, w godzinach największego nasłonecznienia, na uwagę zasługuje odpowiedni dobór charakterystyk falowników $Q(U)$ i $P(U)$ przedstawionych na rys. 11.2 i rys. 11.3.



Rys. 11.1 Poglądowa sieć elektroenergetyczna niskiego napięcia z przyłączonymi mikroinstalacjami PV



Rys. 11.2 Charakterystyka $Q(U)$ falownika instalacji PV




Rys. 11.3 Charakterystyka $P(U)$ falownika instalacji PV

Wymaga to jednak zaangażowania operatorów, tak by certyfikaty przedstawiane przez producentów i instalatorów były rzeczywiste, a nie fikcyjne oraz by operatorzy potrafili wymusić uaktywnienie tych charakterystyk oraz dobór parametrów falowników zgodnie z zaleceniami. To rozwiązanie pozwoli w wielu przypadkach na uniknięcie dodatkowych wydatków na przebudowę sieci i kosztowne urządzenia regulacyjne – transformatory z OLTC oraz transformatory szeregowe. Analiza przeprowadzona w ramach tego podpunktu miała za zadanie wykazać skuteczność optymalnego doboru parametrów, wspomnianych wcześniej charakterystyk, w likwidowaniu przekroczeń napięciowych. Przeprowadzone badania wskazują, że zastosowanie falowników, dla których uaktywniono obydwie charakterystyki pozwala na opanowanie problemu wzrostu napięć, przy niewielkim ograniczeniu energii produkowanej w mikroinstalacji.

11.2 Obliczenia optymalizacyjne

W ramach analizy rozpatrzono obwód z mocą $P_{g\max} = 50$ kW. Zbadano symulacyjnie skuteczność zastosowania charakterystyki $P(U)$ oraz $Q(U)$ (zgodnie z rys. 11.2 i rys. 11.3). Zastosowano każdą charakterystykę osobno oraz obydwie razem (rys. 11.4). O ile znalezienie punktu na jednej charakterystyce jest rzeczą trywialną o tyle zgranie dwóch charakterystyk (o różnych nastawach) nie jest już takie oczywiste i wymaga podejścia iteracyjnego. Należy zauważyć, że zmiana punktu na jednej charakterystyce powoduje automatyczną zmianę napięcia w obwodzie. Czyli nie jest to tylko przeniesienie punktu z jednej krzywej na drugą ale poszukiwanie go poprzez ciągłe rozwiązywanie równań, aż do momentu, gdy jeden punkt będzie spełniał obydwie charakterystyki (przy uwzględnieniu warunków rzeczywistych w obwodzie).



Rys. 11.4 Połączenie charakterystyk $P(U)$ i $Q(U)$ falownika

Trudność rozwiązywania wzrasta, gdy za funkcję celu przyjęta zostanie wartość ograniczenia, możliwej do wyprodukowania energii w mikroinstalacji. Aby ją zminimalizować należy optymalnie dobierać nastawy obydwu charakterystyk. Jeżeli cały proces odbywa się w trybie rzeczywistym (zmiana nasłonecznienia, zmiana obciążenia), wówczas zagadnienie to staje się zadaniem optymalizacyjnym. Na charakterystyce $Q(U)$ punkt pracy wyznacza się w oparciu o równanie nieliniowe dla każdego i -tego okresu symulacji:

$$U_i = U_Z + \frac{\alpha_i P_{g\max}}{U_n} R + \frac{Q_i(U_i)}{U_n} X \quad (11.1)$$


gdzie:

α_i – współczynnik generacji dla i -tego okresu,


U_Z – napięcie na szynach LV (przyjęto stałą wartość),

$Q_i(U_i)$ – moc bierna wg charakterystyki z rys. 11.2.

Na rys. 11.5 i rys. 11.6 przedstawiono wyniki symulacji dla okresu jednego tygodnia (sierpień 2017). Dla mocy instalacji fotowoltaicznej $P_{gi} = \alpha_i P_{g\max}$, przy napięciu $U_Z = 420V$ przekroczenia dopuszczalnej wartości napięcia wystąpią przez 25% kwadransów tygodnia ($U_i > 440 V$) o ile $Q_i = \text{const} = 0$. Zastosowanie charakterystyki $Q(U)$ (nastawienia: $U_{D2}=400V$, $U_{D1}=410V$, $U_Z=420V$, $U_{G1}=430V$, $U_{G2}=440V$) poprawia istotnie jakość napięcia (przekroczenia zredukowane do 10 %). Nie eliminuje jednak wszystkich przekroczeń.



Rys. 11.5 Tygodniowe zmiany mocy generowanej w instalacji fotowoltaicznej $P_{g\max} = 50 \text{ kW}$



Rys. 11.6 Tygodniowe zmiany napięcia w miejscu przyłączenia instalacji PV, przy założeniu $\cos \varphi = 1$ oraz po zastosowaniu charakterystyki $Q(U)$


Na charakterystyce $P(U)$ punkt pracy (U_i, α_i) znajduje się w miejscu przecięcia prostej o równaniu:

$$\alpha_i = tg\gamma(U - U_{SLV}) \quad (11.2)$$


z charakterystyką opisaną jako $\alpha=g(U)$ – rys. 11.4, przy czym

$$tg\gamma = \frac{1}{\frac{P_{g\max}}{U_n} R(1 + tg\varphi tg\varphi_L)} \quad (11.3)$$

Przy odpowiednim doborze parametrów charakterystyki $g(U)$ czyli U_G , U_D i α_k napięcie zostaje skutecznie ograniczone do 440 V (wskaźnik przekroczeń równy zero). Wskaźnik niewykorzystanej energii z instalacji wynosi $\Delta E_{PV}/E_{PV} = 26\%$, co jest wartością możliwą do zaakceptowania, aczkolwiek znaczącą. Efekt skutecznego zastosowania charakterystyki $P(U)$ falownika fotowoltaicznego pokazano na rys. 11.7 i rys. 11.8.




Rys. 11.7 Tygodniowe zmiany mocy generowanej w instalacji fotowoltaicznej $P_{g\max} = 50$ kW przed i po wykorzystaniu charakterystyki $P(U)$




Rys. 11.8 Tygodniowe zmiany napięcia w miejscu przyłączenia instalacji PV, przy założeniu $\cos \varphi = 1$ oraz po zastosowaniu charakterystyki $P(U)$

Dzięki łącznemu zastosowaniu obydwu charakterystyk $P(U)$ i $Q(U)$ można osiągnąć znaczną redukcję wskaźnika niewykorzystanej energii z instalacji. Wartość napięcia również utrzymywana jest poniżej 440 V. Najskuteczniejsze wyniki ograniczenia wzrostu napięcia osiąga się, gdy U_L jest bliskie U_H . Na rys. 11.9 i rys. 11.10 przedstawiono efekty łączenia działania obydwu charakterystyk $P(U)$ i $Q(U)$ inwertera dla $U_L = 435$ V i $U_H = 440$ V. Wskaźnik niewykorzystanej energii został zredukowany trzykrotnie, do wartości 8,3%.




Rys. 11.9 Tygodniowe zmiany mocy w miejscu przyłączenia instalacji fotowoltaicznej przy zastosowanych charakterystykach $P(U)$ i $Q(U)$, ($U_D = 435$ V, $U_G = 440$ V)



Rys. 11.10 Tygodniowe zmiany napięcia w miejscu przyłączenia instalacji fotowoltaicznej przy zastosowanych charakterystykach $P(U)$ i $Q(U)$, ($U_D = 435V$, $U_G = 440V$)

Dla porównania poniżej przedstawiono wpływ zastosowania zabezpieczenia nadnapięciowego na wartość ograniczenia możliwej do wyprodukowania energii. Okazuje się, że stosując to zabezpieczenie z nastawą 440 V napięcie będzie utrzymywane poniżej dopuszczalnego, ale energia zostanie zredukowana do wartości 60% możliwej do wyprodukowania w badanym okresie.




Rys. 11.11 Tygodniowe zmiany mocy w miejscu przyłączenia instalacji fotowoltaicznej przy zastosowaniu zabezpieczenia nadnapięciowego

Zastosowanie zabezpieczeń nadnapięciowych w sieci z dużym nasyceniem mikroinstalacjami będzie powodowało konieczność wyłączania źródeł, szczególnie tych, które są przyłączone na końcach obwodów. Mają one bowiem

największy wpływ na przekroczenia napięciowe. Oczywiście jest to niesprawiedliwe z punktu widzenia właścicieli, toteż konieczne jest stworzenie algorytmu, który pozwalałby sprawiedliwie traktować wszystkich prosumentów. Gdyby moc produkowana w źródłach rozproszonych odpowiadała mocy odbieranej w miejscach ich przyłączenia, wtedy stan sieci odpowiadałby stanowi jałowemu, czyli poborowi mocy z transformatora SN/nn bliskiemu zeru. Specyfika źródeł rozproszonych i zastosowanych technologii polega jednak na tym, że korelacja mocy w nich wytwarzanej z mocą zapotrzebowaną jest znikoma. Mówiąc konkretnie o fotowoltaice, zapotrzebowanie na moc w miesiącach maksymalnego poziomu promieniowania słonecznego, nie pokrywa się ze szczytowym zapotrzebowaniem na moc u odbiorców. Przepływ mocy w kierunku stacji SN/nn powoduje efekt określany jako „podbicie napięcia”, będący odwrotnością efektu spadku napięcia. Tym samym napięcie w punktach przyłączenia źródeł rozproszonych, jak też w punktach przyłączenia instalacji odbiorczych, znajdujących się w ich pobliżu, może wzrastać powyżej wartości dopuszczalnych.

Można sobie wyobrazić zatem układ (rys. 11.12) umożliwiający wysyłanie sygnałów do poszczególnych falowników, które powodowałyby minimalizację ryzyka wzrostu napięcia ponad wartość dopuszczalną i minimalizację redukcji energii elektrycznej. Najtaniej jest generować sygnały dotyczące nastaw charakterystyk $Q(U)$ i $P(U)$.



Rys. 11.12 Koncepcja algorytmu sterowania mikroinstalacjami

Zgodnie z informacjami zawartymi w normach EN 50438 [210] i AS/NZS 4777.2:2015 of New Zealand [211], nastawy charakterystyk $Q(U)$ i $P(U)$ mogą być zmieniane. W związku z tym, zagadnienie to można potraktować jako zadanie

optymalizacji nieliniowej z ograniczeniami i rozwiązać je, wykorzystując metody heurystyczne. Wydaje się, że metody klasyczne nie są tutaj odpowiednie ze względu na iteracyjny charakter problemu. Optymalny dobór nastaw obydwu krzywych ma za zadanie minimalną redukcję możliwej do wyprodukowania energii w mikroinstalacjach.

Zatem rozpatrywana funkcja celu ma postać:

$$F_c(\mathbf{x}, \mathbf{y}, \mathbf{z}) = \frac{\Delta E(\mathbf{x}, \mathbf{y}, \mathbf{z})}{E_c} \cdot 100, \% \quad (11.4)$$

gdzie:

$\mathbf{x} = [U_{D1}, U_{D2}, U_{G1}, U_{G2}, U_D, U_G, \alpha_k]$, – wektor wartości progowych napięć i współczynnika α na charakterystykach $Q(U)$ i $P(U)$ (wektor zmiennych decyzyjnych),

$\mathbf{y} = [P_{L1}, \dots, P_{Li}, Q_{L1}, \dots, Q_{Li}, P_{Gn1}, \dots, P_{Gnn}]$ – wektor mocy odbieranych oraz mocy generowanych nie podlegających regulacji (wektor zmiennych niezależnych),

$\mathbf{z} = [U_1, \dots, U_i, \delta_1, \dots, \delta_i, P_{Gr1}, \dots, P_{Grk}]$ – wektor fazorów napięć węzłowych oraz mocy generowanych w węzłach zapewniających zbilansowanie systemu (wektor zmiennych zależnych).

ΔE – ograniczenie produkcji energii w rozpatrywanej instalacji PV, E_c – energia możliwa do wyprodukowania w rozpatrywanej mikroinstalacji przy założonych warunkach nasłonecznienia.

Ograniczenie zmiennych decyzyjnych (wektora $\mathbf{x}$) dobierano w ten sposób, aby nastawy „nie zachodziły na siebie”. Ograniczenia te stanowią:

- dla charakterystyki $Q(U)$: $421 \text{ V} \leq U_{G1} \leq 430 \text{ V}$, $438 \text{ V} \leq U_{G2} \leq 445 \text{ V}$,
- dla charakterystyki $P(U)$: $421 \text{ V} \leq U_D \leq 439 \text{ V}$, $440 \text{ V} \leq U_G \leq 450 \text{ V}$, $0,2 \leq \alpha_k \leq 0,35$.

Ograniczenia zmiennych zależnych (wektora $\mathbf{z}$) stanowią:

- dopuszczalne wartości napięć w węzłach (generalnie utrzymywane w zakresie od $0,9U_n$ do $1,1U_n$).

Ograniczenia równościowe $g(\mathbf{x}, \mathbf{y}, \mathbf{z})$ stanowią:

- równania węzłowe rozpyłów mocy.

Ograniczenia nierównościowe $h(\mathbf{x}, \mathbf{y}, \mathbf{z})$ stanowią:

- dopuszczalne obciążalności linii elektroenergetycznych,
- dopuszczalna obciążalność transformatora SN/0,4 kV/kV.


Zadanie polega na minimalizacji funkcji celu, poprzez poszukiwanie optymalnych wartości parametrów U_{D1} , U_{D2} , U_{G1} , U_{G2} , U_D , U_G , α_k i utrzymywaniu napięcia w obwodzie poniżej wartości dopuszczalnej. Ponieważ problem dotyczy przekroczeń napięciowych powyżej 440 V, toteż kluczowe znaczenie mają

wielkości U_{G1} , U_{G2} , U_D , U_G , α_k . i te wielkości brano pod uwagę podczas obliczeń, natomiast parametry U_{D1} , U_{D2} i U_Z przyjmowano jako stałe.


W przypadku algorytmu AIG, w obliczeniach założono 10 strzałów. Losowanie kątów korekcyjnych odbywało się przy wykorzystaniu rozkładu normalnego. Dla algorytmu CS założono 10 kukulek, natomiast dla MFO – 10 ciem (MFO) oraz maksymalną liczbę iteracji równą 100. Optymalne wartości nastaw, uzyskane z obliczeń, wynoszą:

- dla charakterystyki $Q(U)$: $U_{G1} = 421$ V, $U_{G2} = 438$ V,
- dla charakterystyki $P(U)$: $U_D = 439$ V, $U_G = 443$ V, $\alpha_k = 0,23$.

Na rys. 11.13 i rys. 11.14 przedstawiono efekty łączenia działania obydwu charakterystyk $P(U)$ i $Q(U)$ inwertera dla optymalnie dobranych nastaw.




Rys. 11.13 Tygodniowe zmiany mocy w miejscu przyłączenia instalacji fotowoltaicznej przy zastosowanych charakterystykach $P(U)$ i $Q(U)$, przy optymalnie dobranych nastawach



Rys. 11.14 Tygodniowe zmiany napięcia w miejscu przyłączenia instalacji fotowoltaicznej przy zastosowanych charakterystykach $P(U)$ i $Q(U)$, przy optymalnie dobranych nastawach

Wskaźnik niewykorzystanej energii został zredukowany do wartości 2,143%. Jest to wartość minimalna, możliwa do uzyskania w danych warunkach, a jej wielkość nie wpływa na efekty ekonomiczne inwestycji w instalację PV. Poniżej przedstawiono przykładowy przebieg procesu optymalizacyjnego, przy wykorzystaniu algorytmów AIG, CS i MFO.



Rys. 11.15 Przykładowy przebieg zmienności najlepszych wartości funkcji celu

Wyniki porównano z pięcioma różnymi metodami heurystycznymi (CS – przeszukiwanie kukułczane, GA – algorytmy genetyczne, MFO – algorytm optymalizacji ćmy, PSO – rój cząstek, SA – symulowane wyżarzanie). Porównanie przedstawiono w tab. 11.1.

Tab. 11.1 Porównanie wyników obliczeń z innymi algorytmami

Algorytm	Optymalne wartości zmiennych					Wartość funkcji celu
	U_D , V	U_G , V	α_k	U_{G1} , V	U_{G2} , V	F_c , %
AIG	439	443	0,23	421	438	2,1432
CS	439	443	0,23	430	439	2,1432
MFO	439	443	0,23	428	438	2,1432
GA	438	443	0,23	422	440	2,15
SA	439	443	0,2	430	438	2,1696
PSO	439	443	0,23	430	438	2,1432

Uzyskane wyniki, przy pomocy algorytmu AIG, są porównywalne (w niektórych przypadkach lepsze) od wyników osiągniętych innymi metodami. Może być on zatem z powodzeniem stosowany do rozwiązywania zagadnienia optymalizacyjnego poruszanego w niniejszym rozdziale.

12. Optymalizacja wyboru punktów podziału w sieci średniego napięcia


12.1 Wprowadzenie

Sieci średnich napięć z reguły projektowane były jako sieci odbiorcze. Punkty rozcięcia tych sieci określano w oparciu o kryterium minimalizacji strat mocy. Obecnie zagadnienie to nabiera znaczenia, chociażby ze względu na coraz większą liczbę źródeł o różnych mocach planowanych do przyłączenia w różnych punktach sieci. Są to z reguły źródła OZE (farmy wiatrowe i fotowoltaiczne), które charakteryzują się trudnym do przewidzenia profilem generacji. Biorąc pod uwagę ich zmienność (ang. *variable generation*) i nakładając na to losowy charakter odbiorców, miejsca podziału mogą się zmieniać i różnić od pierwotnie zakładanych. Problem ten zaczyna nabierać znaczenia w rozległych sieciach, charakteryzujących się długimi odcinkami o różnych przekrojach i licznymi odgałęzieniami. Dotychczasowe metody wyznaczania punktów podziału sieci mogą zawodzić z uwagi na wymiar zagadnienia i niezliczoną liczbę możliwych do wystąpienia stanów pracy. Dobrym podejściem wydaje się być potraktowanie tego zagadnienia, jako zadania optymalizacyjnego. Ponieważ posiada ono cechy losowości i niejako jest w pewien sposób dyskretnie (określamy n punktów podziału z m -tego zbioru) toteż odpowiednim rozwiązaniem może być zastosowanie heurystyki.

12.2 Obliczenia

Przeanalizowano problem optymalnej lokalizacji punktów podziału w sieci średniego napięcia, stanowiącej fragment jednego z rejonów energetycznych, zasilanej z pięciu GPZ-tów 110/15 kV, rys. 12.1.

Moce transformatorów 110/15 kV wynoszą 16 MVA. Sieć składa się z 45 węzłów na magistrali SN, 50 odcinków magistrali linii SN, 50 odbiorów (o łącznej mocy 45,6 MW), zasilanych ze stacji 15/0,4 kV jak i przyłączonych do szyn 15 kV w GPZ 110/15 kV. W rozpatrywanym obszarze pracują trzy źródła fotowoltaiczne o mocach 0,2 MW, 0,2 MW i 0,5 MW i jedna elektrownia wiatrowa o mocy 1 MW. Odgałęzień nie pokazano na rysunku. Należy zaznaczyć, że moce odbiorców przyłączonych do punktów na odgałęzieniach zostały skupione w odpowiednich miejscach na magistrali. Magistrala główna linii wykonana jest przewodami AFL 6-70 o łącznej długości ok. 100 km (łączna długość odcinków linii z odgałęzieniami jest dużo większa). W rozpatrywanej sieci przewidzianych są jest pięć punktów podziału.



Rys. 12.1 Schemat rozpatrywanej sieci średniego napięcia

Jako funkcję celu przyjęto straty mocy:

$$F_c(x, y, z) = \Delta P(x, y, z) \quad (12.1)$$

gdzie:

$\mathbf{x} = [st_1, \dots, st_j]$ – wektor statusów (wyłączony/załączony) odcinków linii SN, stanowiących punkty podziału (wektor zmiennych decyzyjnych),

$\mathbf{y} = [P_{L1}, \dots, P_{Li}, Q_{L1}, \dots, Q_{Li}, P_{Gn1}, \dots, P_{Gnn}]$ – wektor mocy odbieranych oraz mocy generowanych nie podlegających regulacji (wektor zmiennych niezależnych),
 $\mathbf{z} = [U_1, \dots, U_i, \delta_1, \dots, \delta_i]$ – wektor fazorów napięć węzłowych (wektor zmiennych zależnych).

Zbiór możliwych kombinacji zmiennych decyzyjnych (wektora $\mathbf{x}$) przedstawiono poniżej:

Tab. 12.1 Zbiór możliwych kombinacji poszczególnych zmiennych decyzyjnych (wektora $\mathbf{x}$)

Lp.	x_i	Nr węzła pocz.	Nr węzła końc.
1	x_1	2	4
2		4	5
3		5	6
4		6	7
5		7	8
6		8	9
7		9	10
8		10	11
9		11	12
10		12	13
11		13	14
12		14	15
13		15	16
14	x_2	16	17
15		16	22
16		17	18
17		18	19
18		19	20
19		22	23
20		23	24
21		24	25
22		25	26
23		26	27
24		27	28
25		28	31
26		31	32
27		32	33
28		33	29
29	x_3	10	34
30		34	35
31		35	45
32		45	46
33		46	47
34		47	48

Lp.	x_i	Nr węzła pocz.	Nr węzła końc.
35		48	49
36		49	50
37	x_4	35	36
38		36	37
39		37	38
40		38	39
41		39	40
42		40	41
43		41	42
44		42	43
45	x_5	29	51
46		51	52
47		52	53
48		53	54
49		54	55
50		45	55

Ograniczenia zmiennych zależnych (wektora $\mathbf{z}$) stanowią:

- dopuszczalne wartości napięć w węzłach (generalnie utrzymywane w zakresie od $0,9U_n$ do $1,1U_n$).

Ograniczenia równościowe $\mathbf{g}(\mathbf{x}, \mathbf{y}, \mathbf{z})$ stanowią:

- równania węzłowe rozpliwów mocy.

Ograniczenia nierównościowe $\mathbf{h}(\mathbf{x}, \mathbf{y}, \mathbf{z})$ stanowią:

- dopuszczalne obciążalności linii elektroenergetycznych,
- dopuszczalne obciążalności transformatorów.


W przypadku algorytmu AIG, w obliczeniach założono 5 strzałów. Losowanie kątów korekcyjnych odbywało się przy wykorzystaniu rozkładu równomiernego. Dla algorytmu CS założono 5 kukulek, natomiast dla MFO – 5 ciem oraz maksymalną liczbę iteracji równą 100.

Na podstawie uzyskanych wyników można stwierdzić, że:

w stanie z maksymalnym obciążeniem:


- dla maksymalnej generacji w źródłach PV i FW, optymalne punkty podziału to wyłączenie linii pomiędzy węzłami 11–12, 24–25, 35–45, 35–36 oraz 45–55, straty mocy, przy takiej strukturze sieci wynoszą 0,264 MW.

Przykładowy przebieg procesu optymalizacji (dla algorytmów AIG, CS, MFO) przedstawiono na rys. 12.2.



Rys. 12.2 Przebieg zmienności najlepszych wartości funkcji celu


dla zerowej generacji w źródłach PV i FW, optymalne punkty podziału to wyłączenie linii pomiędzy węzłami 10–11, 22–23, 35–45, 35–36 oraz 45–55, straty mocy, przy takiej strukturze sieci wynoszą 0,335 MW. Przebieg procesu optymalizacji (dla algorytmów AIG, CS, MFO) przedstawiono na rys. 12.3.



Rys. 12.3 Przebieg zmienności najlepszych wartości funkcji celu


w stanie z minimalnym obciążeniem (równym 10% znamionowego):

dla maksymalnej generacji w źródłach PV i FW, optymalne punkty podziału to wyłączenie linii pomiędzy węzłami 11–12, 32–33, 10–34, 35–36 oraz 45–55, straty mocy, przy takiej strukturze sieci wynoszą 8,806 kW. Przebieg procesu optymalizacji (dla algorytmów AIG, CS, MFO) przedstawiono na rys. 12.4.



Rys. 12.4 Przebieg zmienności najlepszych wartości funkcji celu

- dla zerowej generacji w źródłach PV i FW, optymalne punkty podziału to wyłączenie linii pomiędzy węzłami 6–7, 16–22, 10–34, 35–36 oraz 54–55, straty mocy, przy takiej strukturze sieci wynoszą 6,411 kW. Przebieg procesu optymalizacji (dla algorytmów AIG, CS, MFO) przedstawiono na rys. 12.5.



Rys. 12.5 Przebieg zmienności najlepszych wartości funkcji celu

Wyniki uzyskane za pomocą algorytmu AIG są lepsze lub pokrywają się z wynikami uzyskanymi za pomocą algorytmów MFO i CS. Z wykresów wynika, że we wszystkich przypadkach wystarczyło ok. 40–50 iteracji do znalezienia optymalnego rozwiązania. Wykorzystana do obliczeń sieć testowa, zawierająca zarówno odbiory o zmieniających się wartościach jak i losową generację w źródłach odnawialnych, uzasadnia konieczność sięgania po heurystyczne metody optymalizacji. Przyłączanie do sieci średniego i niskiego napięcia coraz większej liczby nieprzewidywalnych źródeł OZE, w przyszłości będzie wymagało korzystania z coraz bardziej zaawansowanych algorytmów optymalizujących pracę sieci i upoważniających do opisywania jej przymiotnikiem *smart*.

13. Optymalne sterowanie urządzeniami do regulacji przepływów mocy czynnej


13.1 Minimalizacja nieplanowanych przepływów mocy

W rozdziale tym rozpatrzono problem minimalizacji nieplanowanych przepływów mocy w sieci (ang. *unscheduled flows*), występujących niekiedy pomiędzy poszczególnymi systemami. Przykładem może być system polski i niemiecki oraz dwa połączenia występujące pomiędzy nimi. Z uwagi na dużą generację mocy w farmach wiatrowych na północy Niemiec znaczna jej część przepływa siecią PSE w stronę południową i dalej wraca do SEE Niemiec zasilając obszary na południu o dużym zapotrzebowaniu.

Niekontrolowane przepływy mocy są dużym problemem dla operatorów systemu ponieważ zwiększając obciążenie sieci przyczyniają się do wzrostu strat i zagrożenia bezpieczeństwa połączonych SEE. Rozwiązaniem problemu mogą być przesuwniki fazowe PST (ang. *phase shifting transformers*), odpowiednio sterowane. Jeżeli w sieci zainstalowanych będzie kilka tego typu urządzeń, to mogą one niekorzystnie wpływać na jej pracę, z powodu negatywnych interakcji. Dlatego też konieczna jest odpowiednia koordynacja ich nastawień.

13.1.1 Opis sieci testowej

Do badań wybrana została sieć testowa IEEE 96-węzłowa. Składa się ona z trzech obszarów połączonych pomiędzy sobą czterema liniami (rys. 13.1).



Rys. 13.1 Sieć testowa IEEE 96-Bus [216]

Na trzy obszary składa się 96 węzłów, 106 linii, 4 transformatory, 33 źródeł i 51 odbiorów. W stanie bazowym obszar trzeci jest zbilansowany. Obszar drugi posiada mniejszą generację niż zapotrzebowanie, co powoduje przepływy mocy bezpośrednio z obszaru pierwszego (ok. 136 MW) oraz poprzez obszar trzeci (144 MW, sytuacja analogiczna jak w systemie polskim i niemieckim, opisana powyżej). Przepływ mocy przez obszar trzeci jest niepożądany, dlatego też celem poniższych obliczeń jest jego minimalizacja.

13.1.2 Obliczenia

Funkcją celu jest suma wartości bezwzględnych mocy na liniach wymiany pomiędzy obszarami sąsiednimi:

$$F_c(\mathbf{x}, \mathbf{y}, \mathbf{z}) = \sum_{i,j} |P_{i-j}(\mathbf{x}, \mathbf{y}, \mathbf{z})| \quad (13.1)$$

gdzie:

$\mathbf{x} = [\delta_{PST1}, \dots, \delta_{PSTl}]$ – wektor kątów przesuwników fazowych (wektor zmiennych decyzyjnych),

$\mathbf{y} = [P_{L1}, \dots, P_{Li}, Q_{L1}, \dots, Q_{Li}, P_{Gn1}, \dots, P_{Gnm}]$ – wektor mocy odbieranych oraz mocy generowanych nie podlegających regulacji (wektor zmiennych niezależnych),

$\mathbf{z} = [U_1, \dots, U_i, \delta_1, \dots, \delta_i]$ – wektor fazorów napięć węzłowych (wektor zmiennych zależnych).

P_{i-j} – moc wymiany pomiędzy obszarami i oraz j .

Ograniczenie zmiennych decyzyjnych (wektora $\mathbf{x}$) stanowią:

- dopuszczalne wartości kątów przesuwników fazowych, założono że regulacja odbywać się będzie w zakresie $\pm 30^\circ$.

Ograniczenia zmiennych zależnych (wektora $\mathbf{z}$) stanowią:

- dopuszczalne wartości napięć w węzłach (generalnie utrzymywane w zakresie od $0,9U_n$ do $1,1U_n$).

Ograniczenia równościowe $\mathbf{g}(\mathbf{x}, \mathbf{y}, \mathbf{z})$ stanowią:


- równania węzłowe rozplądów mocy.

Ograniczenia nierównościowe $\mathbf{h}(\mathbf{x}, \mathbf{y}, \mathbf{z})$ stanowią:

- dopuszczalne obciążalności linii elektroenergetycznych,
- dopuszczalne obciążalności transformatorów.

W przypadku algorytmu AIG, w obliczeniach założono 10 strzałów. Losowanie kątów korekcyjnych odbywało się przy wykorzystaniu rozkładu normalnego. Dla algorytmu CS założono 10 kukulek, natomiast dla MFO – 10 cieni oraz maksymalną liczbę iteracji równą 100.

Do dalszych analiz, zamodelowano przesuwniki fazowe na czterech liniach wymiany (pomiędzy obszarami 1–3 i 3–2) i przeprowadzono obliczenia optymalizacyjne mające na celu minimalizację nieplanowanych przepływów pomiędzy tymi obszarami. Proponowany algorytm AIG pozwolił ograniczyć całkowity przepływ mocy do wartości 0,5 MW. Optymalne nastawy PST wyniosły $-15,1^\circ$, $-15,4^\circ$, $-12,5^\circ$, $12,7^\circ$.



Rys. 13.2 Przebieg zmienności najlepszych wartości funkcji celu, (metoda AIG, CS, MFO)


13.2 Odciążanie przeciążonych elementów SEE

Występujące przeciążenia elementów SEE można likwidować między innymi za pomocą metod opisanych w punkcie 7. Innym sposobem jest wykorzystanie transformatorów z regulacją poprzeczną lub wzdłużno-poprzeczną.

Jako przykład wykorzystano fragment sieci KSE, przedstawionej w punkcie 7. Założono, że w regulację wzdłużno-poprzeczną wyposażone będą niektóre jednostki transformatorowe zainstalowane pomiędzy siecią 110 kV, widoczną na rysunku, a siecią przesyłową (parametry sieci przesyłowej są identyczne jak w rozdziale 7). Tym samym, do regulacji wytypowano:

- dwa transformatory w stacji systemowej S5 (ze względu na to, że systemy szyn po stronie 110 kV są rozpięte, istnieją dwa niezależne ciągi liniowe 110 kV),
- jeden transformator w stacji systemowej S1,
- jeden transformator w stacji systemowej S2,
- jeden transformator w stacji systemowej S3.

W sumie założono zatem pięć takich urządzeń (oznaczonych na rys. 13.3 jako PF) o dopuszczalnym zakresie regulacji kąta wynoszącym $-30^\circ \leq \delta \leq 30^\circ$. Stwierdzono, że w stacjach systemowych S4, S6 i S7 nie będą one stosowane.



Rys. 13.3 Fragment analizowanej sieci 110 kV wraz z zaznaczonymi miejscami z transformatorami z regulacją wzdłużno-poprzączną (w węzłach S1 ... S7 sieć 110 kV jest połączona z siecią przesyłową niepokazaną na rysunku)

Celem takiego postępowania było wyeliminowanie przeciążeń prądowych linii elektroenergetycznych 110 kV poprzez optymalną regulację przepływami mocy czynnej w analizowanym obszarze sieci.

Za funkcję celu przyjęto różnicę względnych wartości pomiędzy stopniem obciążenia linii a dopuszczalną obciążalnością prądową elementu przeciążonego, według zależności:

$$F_c(\mathbf{x}, \mathbf{y}, \mathbf{z}) = \sum_i \left(\frac{I_i(\mathbf{x}, \mathbf{y}, \mathbf{z})}{I_{idop}} - 1 \right)^2 \quad (13.2)$$

gdzie:

$\mathbf{x} = [\delta_{PF1}, \dots, \delta_{PFi}]$ – wektor kątów przekładni transformatorów (wektor zmiennych decyzyjnych),

$\mathbf{y} = [P_{L1}, \dots, P_{Li}, Q_{L1}, \dots, Q_{Li}, P_{Gn1}, \dots, P_{Gnm}]$ – wektor mocy odbieranych oraz mocy generowanych nie podlegających regulacji (wektor zmiennych niezależnych),

$\mathbf{z} = [U_1, \dots, U_i, \delta_1, \dots, \delta_i]$ – wektor fazorów napięć węzłowych (wektor zmiennych zależnych).

I_i – wartość prądu i -tej linii przeciążonej,

I_{idop} – dopuszczalna obciążalność i -tej linii przeciążonej.

Ograniczenie zmiennych decyzyjnych (wektora $\mathbf{x}$) stanowią:

- dopuszczalne wartości kątów przekładni transformatorów, założono że regulacja odbywać się będzie w zakresie $\pm 30^\circ$.

Ograniczenia zmiennych zależnych (wektora $\mathbf{z}$) stanowią:

- dopuszczalne wartości napięć w węzłach (generalnie utrzymywane w zakresie od $0,9U_n$ do $1,1U_n$).

Ograniczenia równościowe $\mathbf{g}(\mathbf{x}, \mathbf{y}, \mathbf{z})$ stanowią:

- równania węzłowe rozpliwów mocy.

Ograniczenia nierównościowe $\mathbf{h}(\mathbf{x}, \mathbf{y}, \mathbf{z})$ stanowią:

- dopuszczalne obciążalności linii elektroenergetycznych,
- dopuszczalne obciążalności transformatorów.

W przypadku algorytmu AIG, w obliczeniach założono 10 strzałów. Losowanie kątów korekcyjnych odbywało się przy wykorzystaniu rozkładu normalnego. Dla algorytmu CS założono 10 kukulek, natomiast dla MFO – 10 ciem oraz maksymalną liczbę iteracji równą 50.

Możliwe są oczywiście inne postacie funkcji celu, takie jak maksymalizacja zapasu przepustowości gałęzi, minimalizacja liczby transformatorów z regulacją skośną czy minimalizacja liczby przeciążonych elementów badanego obszaru sieci. Poniżej przedstawiono wyniki obliczeń dla stanu normalnego i wybranego stanu „N-1”.


– Stan normalny

Obliczenia wykonano dla stanu normalnego, opisanego w punkcie 7.2. Aby zlikwidować przeciążenia linii, należało ograniczyć moc w źródłach o 19 MW. Można tego uniknąć (co daje wymierne korzyści finansowe) poprzez odpowiednie sterowanie przepływami mocy czynnej.

W niniejszym przykładzie wystarczyło odpowiednio optymalnie ustawić przekładnię kątową pięciu transformatorów. Wyniki uzyskane za pomocą algorytmu AIG przedstawiono poniżej:

- dla transformatorów w stacji systemowej S5, nastawy kątowe to $12,5^\circ$ i $7,5^\circ$,
- dla transformatora w stacji systemowej S1, nastawa kątowa to $-7,5^\circ$,
- dla transformatora w stacji systemowej S2, nastawa kątowa to 5° ,
- dla transformatora w stacji systemowej S3, nastawa kątowa to $-3,5^\circ$.

Na rys. 13.4 przedstawiono przebieg zmienności najlepszych wartości funkcji celu według algorytmów AIG, CS i MFO. Wynika z niego brak przeciążeń w analizowanej sieci,



Rys. 13.4 Przebieg zmienności najlepszych wartości funkcji celu, (algorytm AIG, CS, MFO)


– **Wyłączona linia pomiędzy węzłami nr 29–41**

Obliczenia wykonano dla jednego ze stanów „N-1”, polegającego na wyłączeniu linii 110 kV pomiędzy węzłami nr 29–41. Jest to stosunkowo „trudny” stan awaryjny ponieważ, aby zlikwidować przeciążenia linii, należy ograniczyć moc w źródłach o 201 MW. Można tego uniknąć (co daje wymierne korzyści finansowe) poprzez odpowiednie sterowanie przepływami mocy czynnej. W niniejszym przykładzie wystarczyło odpowiednio ustawić przekładnię kątową pięciu transformatorów, rozwiązując zadanie optymalizacyjne (13.2).

Wyniki uzyskane za pomocą algorytmu AIG przedstawiono poniżej:

- dla transformatorów w stacji systemowej S5, nastawy kątowe to 14° i $6,5^{\circ}$,
- dla transformatora w stacji systemowej S1, nastawa kątowa to $-4,5^{\circ}$,
- dla transformatora w stacji systemowej S2, nastawa kątowa to $5,5^{\circ}$,
- dla transformatora w stacji systemowej S3, nastawa kątowa to $-3,5^{\circ}$.

Na rys. 13.6 przedstawiono przebieg zmienności najlepszych wartości funkcji celu według algorytmów AIG, CS i MFO. Również i w tym przypadku przeciążenia zostały wyeliminowane.



Rys. 13.5 Przebieg zmienności najlepszych wartości funkcji celu, (algorytm AIG, CS, MFO)

W stanie, z wyłączoną linią pomiędzy węzłami nr 29–41, rozpatrzono również inną funkcję celu, a mianowicie minimalizację liczby przeciążonych elementów badanego obszaru sieci, według zależności:

$$F_c(\mathbf{x}, \mathbf{y}, \mathbf{z}) = \sum_i i \quad (13.3)$$

gdzie: i – i -ta linia przeciążona,

$\mathbf{x} = [\delta_{PF1}, \dots, \delta_{PFi}]$ – wektor kątów przekładni transformatorów (wektor zmiennych decyzyjnych),

$\mathbf{y} = [P_{L1}, \dots, P_{Li}, Q_{L1}, \dots, Q_{Li}, P_{Gn1}, \dots, P_{Gnm}]$ – wektor mocy odbieranych oraz mocy generowanych nie podlegających regulacji (wektor zmiennych niezależnych),

$\mathbf{z} = [U_1, \dots, U_i, \delta_1, \dots, \delta_i]$ – wektor fazonów napięć węzłowych (wektor zmiennych zależnych).

Ograniczenie zmiennych decyzyjnych (wektora $\mathbf{x}$) stanowią:

- dopuszczalne wartości kątów przekładni transformatorów, założono że regulacja odbywać się będzie w zakresie $\pm 30^\circ$.

Ograniczenia zmiennych zależnych (wektora $\mathbf{z}$) stanowią:

- dopuszczalne wartości napięć w węzłach (generalnie utrzymywane w zakresie od $0,9U_n$ do $1,1U_n$).

Ograniczenia równościowe $g(\mathbf{x}, \mathbf{y}, \mathbf{z})$ stanowią:

- równania węzłowe rozływów mocy.

Ograniczenia nierównościowe $h(x, y, z)$ stanowią:


- dopuszczalne obciążalności linii elektroenergetycznych,
- dopuszczalne obciążalności transformatorów.

W przypadku algorytmu AIG, w obliczeniach założono 10 strzałów. Losowanie kątów korekcyjnych odbywało się przy wykorzystaniu rozkładu normalnego. Dla algorytmu CS założono 10 kukulek, natomiast dla MFO – 10 ciem oraz maksymalną liczbę iteracji równą 50.

Wyniki uzyskane za pomocą algorytmu AIG przedstawiono poniżej:

- dla transformatorów w stacji systemowej S5, nastawy kątowe to $6,5^\circ$ i 6° ,
- dla transformatora w stacji systemowej S1, nastawa kątowa to $-1,5^\circ$,
- dla transformatora w stacji systemowej S2, nastawa kątowa to 6° ,
- dla transformatora w stacji systemowej S3, nastawa kątowa to $-5,5^\circ$.

Na rys. 13.6 przedstawiono przebieg zmienności najlepszych wartości funkcji celu według algorytmów AIG, CS i MFO.



Rys. 13.6 Przebieg zmienności najlepszych wartości funkcji celu, (algorytm AIG, CS, MFO)

Należy jednocześnie zwrócić uwagę na fakt, że w praktyce nie wszystkie przeciążone linie udaje się odciążyć bez redukcji mocy generowanej w źródłach. Ma to miejsce wtedy, gdy w stanach „ $N-1$ ” powstają ciągi promieniowe. Dlatego też odpowiednie jest łączenie kilku metod naraz, tak aby w maksymalny sposób wykorzystać bezinwazyjne sposoby odciążania.

14. Minimalizacja kosztów bilansowania zapotrzebowania na moc w SEE

14.1 Wprowadzenie


Planowanie i sterowanie pracą systemu elektroenergetycznego jest procesem wymagającym rozwiązania wielu skomplikowanych i wzajemnie powiązanych zadań teoretycznych oraz problemów technologicznych. Pomimo znaczącego rozwoju metod dotyczących identyfikacji i optymalizacji stanów poszczególnych obiektów systemu elektroenergetycznego oraz szybkiego postępu w dziedzinie informatyzacji systemu, ciągle jeszcze w planowaniu pracy i sterowaniu pracą systemu dokonuje się szeregu uproszczeń. Rozdział ten poświęcony jest zagadnieniu optymalizacji kosztów bilansowania mocy zapotrzebowanej w systemie elektroenergetycznym. Zależą one od wielu czynników. Zadanie minimalizacji kosztów bilansowania systemu elektroenergetycznego należy zaliczyć do zagadnień optymalizacji nieliniowej. Dotychczas stosowane sposoby ich wyznaczania bazują zazwyczaj na linearyzacji zagadnienia rozprężu mocy. W praktyce jednak takie podejście może stanowić zbyt duże uproszczenie. Dlatego też należy szukać innych, bardziej dokładnych algorytmów.

14.2 Opis sieci testowej

Do obliczeń wykorzystano sieć testową CIGRE (rys. 14.1), która pracuje na poziomie napięcia 220 kV. Sieć składa się z 10 węzłów, 13 gałęzi, 10 odbiorów, 7 źródeł. W tab. 14.1 przedstawiono listę źródeł wraz z założonymi cenami energii elektrycznej.

Tab. 14.1 Lista źródeł wraz z optymalnymi wartościami napięć

Lp	Nazwa generatora	Moc minimalna	Moc maksymalna	Moc generowana	Koszt Przypadek 1	Koszt Przypadek 2
-	-	$P_{\min}$ MW	$P_{\max}$ MW	P_{gen} MW	c zł/MWh	c zł/MWh
1	B01_211	100	800	100	145	150
2	B02_211	100	800	100	140	150
3	B03_211	100	800	210	160	150
4	B04_211	100	1000	295,83	160	150
5	B05_211	100	800	210	140	150
6	B06_211	100	800	300	150	150
7	B07_211	100	800	150	155	150



Rys. 14.1 Sieć testowa CIGRE.

14.3 Obliczenia

Chcąc wyznaczyć minimalne koszty bilansowania SEE, funkcja celu zadania OPF powinna być określona następująco [141]:

$$F_c(\mathbf{x}, \mathbf{y}, \mathbf{z}) = \sum_{j=1}^{N_z} c_j \cdot x_j \quad (14.1)$$

gdzie:

$\mathbf{x} = [P_{G1}, \dots, P_{Gi}]$ – wektor mocy czynnych generowanych przez rozpatrywane źródła wytwórcze (wektor zmiennych decyzyjnych),

$\mathbf{y} = [P_{L1}, \dots, P_{Li}, Q_{L1}, \dots, Q_{Li}, P_{Gn1}, \dots, P_{Gnm}]$ – wektor mocy odbieranych oraz mocy generowanych nie podlegających regulacji (wektor zmiennych niezależnych),

$\mathbf{z} = [U_1, \dots, U_i, \delta_1, \dots, \delta_i, P_{Gr1}, \dots, P_{Grk}]$ – wektor fazy napięć węzłowych oraz mocy generowanych w węzłach zapewniających zbilansowanie systemu (wektor zmiennych zależnych).

Ograniczenie zmiennych decyzyjnych (wektora $\mathbf{x}$) przedstawiono w tab. 14.2:

Tab. 14.2 Ograniczenia zmiennych decyzyjnych (wektora x)

Lp	Nazwa generatora	P_{Gjmin} MW	P_{Gjmax} MW
1	B01_211	100	800
2	B02_211	100	800
3	B03_211	100	800
4	B04_211	100	1000
5	B05_211	100	800
6	B06_211	100	800
7	B07_211	100	800

Ograniczenia zmiennych zależnych (wektora z) stanowią:

- dopuszczalne wartości napięć w węzłach (generalnie utrzymywane w zakresie od $0,9U_n$ do $1,1U_n$).

Ograniczenia równościowe $g(x, y, z)$ stanowią:

- równania węzłowe rozptyłów mocy,

Ograniczenia nierównościowe $h(x, y, z)$ stanowią:

- dopuszczalne obciążalności linii elektroenergetycznych,
- dopuszczalne obciążalności transformatorów.

W obliczeniach, dla algorytmu AIG, założono 10 strzałów. Losowanie kątów korekcyjnych odbywało się przy wykorzystaniu rozkładu normalnego.

Funkcja celu stanowi sumę iloczynów elementów wektora zmiennych decyzyjnych (mocy generowanych w źródłach wytwórczych), odpowiadających rozpatrywanym węzłom sieci (ich liczba jest określona jako N_Z) oraz cen c . Mając wyznaczony minimalny koszt bilansowania zapotrzebowania SEE można wyznaczyć krótkookresowe ceny węzłowe w poszczególnych węzłach sieci. Zgodnie z definicją, krótkookresowa cena węzłowa oznaczana jako LMP (ang. *Locational Marginal Price*), wyraża się wzorem [217]:

$$LMP_j = \frac{\partial K(P_G)}{\partial P_{Lj}} \quad (14.2)$$

gdzie:

$\partial K(P_G)$ – minimalna zmiana kosztu bilansowania zapotrzebowania SEE,

∂P_{Lj} – zmiana mocy odbieranej w węźle j .

Ponieważ za pomocą metod heurystycznych operuje się, w trakcie obliczeń, konkretnymi wartościami funkcji celu w punkcie, toteż krótkookresową cenę węzłową w wybranym węźle sieci wyznaczano jako iloraz różnicy minimalnych kosztów bilansowania i różnicy wartości mocy pobieranej w tymże węźle [140].

Założono, że wartość tej różnicy wynosi 5 MW. Czyli obliczenia polegały na określeniu dwóch stanów optymalnych i odniesieniu różnicy kosztów bilansowania SEE do zmiany mocy pobieranej w wybranym węźle, według zależności

$$LMP_j = \frac{\Delta K(\mathbf{P}_G)}{\Delta P_{Lj}} \quad (14.3)$$


Jest to oczywiście pewne uproszczenie, ale kompensowane tym, że w przypadku metod heurystycznych można prowadzić obliczenia na modelu zmiennoprądowym niezależnie od wymiaru zagadnienia (metody klasyczne trudno jest zastosować w przypadku dużych sieci).

Stan bazowy sieci testowej CIGRE charakteryzował się brakiem przekroczeń prądowych i napięciowych. Zapotrzebowanie na moc czynną wynosiło 1342 MW. Straty mocy czynnej w tym stanie wynosiły 24,44 MW. Sumaryczna moc czynna generowana wynosiła 1365,83 MW.


Obliczenia wykonano dla dwóch przypadków:

- różne ceny ofertowe energii elektrycznej,
- jednakowe ceny ofertowe energii elektrycznej (założono 150 zł/MWh).

Wyniki obliczeń uzyskane za pomocą proponowanego algorytmu AIG porównano z wynikami uzyskanymi za pomocą metody symulowanego wyżarzania i roju cząstek zaczerpniętymi z pracy [140]. Na rys. 14.2 i rys. 14.3 przedstawiono zmienność najlepszych wartości funkcji celu dla algorytmu AIG.



Rys. 14.2 Przebieg zmienności najlepszych wartości funkcji celu w zł, (różne ceny ofertowe energii elektrycznej – metoda AIG)



Rys. 14.3 Przebieg zmienności najlepszych wartości funkcji celu w zł, (jednakowe ceny ofertowe energii elektrycznej – metoda AIG)

W tab. 14.3 i tab. 14.4 przedstawiono wyniki obliczeń dla cen węzłowych, uzyskane za pomocą algorytmu AIG oraz symulowanego wyżarzania i roju cząstek [140]. W tabelach podane są trzy wartości cen odpowiednio dla AIG, SA, PSO.

Tab. 14.3 Lista źródeł, w których zadawana jest wartość mocy czynnej – stan optymalny

Lp	Nazwa generatora	Moc generowana, MW	
		Przypadek 1	Przypadek 2
-	-	Koszty różne	Koszty równe
1	B01_211	200,7/150,9/100	104,6/100,318/100
2	B02_211	495,7/425,1/429,3	148,5/162/141,5
3	B03_211	100/100/100	183,7/149,4/143,8
4	B04_211	100/100/100	481,3/491,9/518,1
5	B05_211	271,7/286,8/331,9	100/100,4/100
6	B06_211	104,6/208,1/214,5	174,9/213,9/209,7
7	B07_211	105/102,4/100	168,6/143,4/148,5
Suma		1377/1373,4/1375,7	1361,5/1361,6/1361,6
Koszt bilansowania zł		200600/200810,2/200823,4	204197/204234,6/204238,5

**Tab. 14.4 Lista węzłów, wraz z ich cenami węzłowymi (odpowiednio dla algorytmów
AIG, SA, PSO)**

Lp	Nazwa węzła	Cena węzłowa, zł/MWh	
		Przypadek 1	Przypadek 2
-	-	Koszty różne	Koszty równe
1	B01211	141/145,6/143	150/150/150
2	B02211	139/140/140	150/150/150
3	B03211	144,2/146,9/144,3	150/150/150
4	B04211	144/146,8/144,2	150/150/150
5	B05211	140/140/140	150/150/150
6	B06211	149/151,8/149,2	150/150/150
7	B07211	150/151,6/149	150/150/150
8	B08211	151/154,8/152,1	153,5/153,9/155,4
9	B09211	185/188,5/185,8	155,8/158/157,2
10	B10211	146/150,5/147,9	155,1/154,1/153,3

W pierwszym przypadku największa moc generowana jest przez źródło o najmniejszej cenie energii, lecz prowadzi to do powiększenia strat mocy, w stosunku do stanu bazowego. W drugim przypadku, przy jednakowych cenach energii, algorytm stara się minimalizować straty mocy, które uległy zmniejszeniu w stosunku do stanu bazowego.

Podsumowanie

Główną tematyką niniejszej monografii jest optymalizacja w elektroenergetyce. Od samego początku, autor prezentuje stanowisko polegające na unikaniu (czy też ograniczaniu liczby) założeń upraszczających stosowanych w zagadnieniach optymalizacji występujących w problemach inżynierskich. Mówiąc o systemie elektroenergetycznym jako całości sprowadza się to do uwzględniania, w miarę możliwości, wszystkich czynników, które warunkują dane zagadnienie.

W pierwszym okresie stosowania obliczeń komputerowych w SEE pojęcie optymalizacji w systemie elektroenergetycznym dotyczyło głównie poszukiwania takiego rozdziału wytwarzanej mocy na pracujące jednostki wytwórcze, aby sumaryczny koszt wytwarzania był minimalny. Rozwiązanie tego zadania (ERO, ang. *Economic Dispatch* [1]) było możliwe pod warunkiem znajomości charakterystyk kosztów wytwarzania poszczególnych źródeł. Zagadnienie to było rozwiązywane za pomocą funkcji Lagrange'a i przy wykorzystaniu warunków dostatecznych i koniecznych istnienia jej ekstremum. Wprowadzenie algorytmów i metod numerycznych, pozwalających na uwzględnienie w obliczeniach modelu węzłowego sieci elektroenergetycznej, doprowadziło do sformułowania problemu poszukiwania optymalnego rozprywu mocy. Zagadnienie to, określane jako OPF [1] (ang. *Optimal Power Flow*), nie jest obecnie trudne do rozwiązania przy zastosowaniu współcześnie stosowanych metod numerycznych i sprzętu obliczeniowego. Można tu zastosować jedną z klasycznych metod optymalizacji nieliniowej z ograniczeniami.

Problemy zaczynają się mnożyć, gdy bierze się pod uwagę zagadnienia występujące pod nazwą SCOPF (ang. *Security Constrained Optimal Power Flow*), które uwzględniają kryterium „N-1”. Wówczas typowe metody klasyczne zaczynają zawodzić i stąd konieczność poszukiwania nowych algorytmów, np. heurystycznych, które pozwolą z akceptowalną dokładnością rozwiązać dany problem bez wprowadzania założeń upraszczających. Do takich uproszczeń można zaliczyć niewątpliwie te, na bazie których powstała np. metoda stałoprądowa wyznaczania rozprływów mocy, która jest chętnie wykorzystywana przez twórców oprogramowania stosowanego w elektroenergetyce. Aby uświadomić sobie trudność w stworzeniu efektywnego narzędzia komputerowego do rozwiązywania powyższych zagadnień należy podkreślić, że tylko programy komercyjne wykorzystywane do analizy SEE zawierają narzędzia tego typu. Mało tego, wiele z tych programów opiera się na linearyzacji zagadnienia co jest pewnym uproszczeniem i może niekiedy prowadzić do błędnych wniosków, szczególnie przy analizie dużych sieci. Kilkunastoletnie doświadczenie autora, związane z realizacją ekspertyz przyłączeniowych, projektów badawczych i różnych innych prac w zakresie elektroenergetyki, wskazują na występowanie wielu problemów dotyczących systemu elektroenergetycznego, które mogą być rozwiązane poprzez zastosowanie optymalizacji.

Jak stwierdzono we wstępie, zagadnienia te charakteryzują się znaczną złożonością funkcji celu, dyskretnym charakterem dziedziny funkcji, dużym wymiarem zadania, czy możliwością wystąpienia rozbieżnego procesu iteracyjnego. Jeżeli na powyższe nałoży się konieczność spełnienia kryterium „ $N-1$ ”, czy inne warunki i ograniczenia narzucane przez operatorów systemu, wówczas wzrasta rozmiar zagadnienia i komplikuje się ono na tyle, że metody klasyczne stają się nieefektywne czy wręcz nieodpowiednie do jego rozwiązania. Biorąc pod uwagę powyższe trudności, zastosowanie heurystyki w elektroenergetyce wydaje się być uzasadnione, a nawet konieczne.

Niniejsza monografia poświęcona jest heurystycznym metodom optymalizacji, które mogą być stosowane w elektroenergetyce. Dokonano w niej przeglądu dostępnej literatury światowej dotyczącej tej tematyki. Doświadczenia autora, związane z zagadnieniami optymalizacji w elektroenergetyce, wskazują na konieczność poszukiwania nowych algorytmów do rozwiązywania nietypowych problemów inżynierskich. Powyższe przesłanki zainspirowały autora do poszukiwania nowej metody optymalizacji heurystycznej, Algorytmu Innowacyjnego Artylerzysty (ang. *Algorithm of Innovative Gunner – AIG*), zwanego również algorytmem balistycznym.

Jego innowacyjność wynika ze specyficznego i oryginalnego sposobu wyznaczania kolejnych rozwiązań w procesie iteracyjnym. Stanowi on zasadniczą różnicę w stosunku do większości metod, w których w kolejnym kroku element korygujący jest dodawany do poprzedniego rozwiązania. W wyniku inspiracji lekturą militarną, powstał pomysł korekty wektora rozwiązań (pierwotnie kąta strzału) za pomocą mnożników multiplikatywnych. Wydawać by się mogło, że metoda przypomina chaotyczny ostrzał artyleryjski, ale okazuje się, że jest bardzo efektywna, i szybko określa właściwy kierunek poszukiwań, w wyniku czego odnajduje rozwiązanie optymalne. Rozwiązanie to jest powtarzalne, a wyniki są porównywalne (**w wielu przypadkach wyraźnie lepsze**) z innymi algorytmami stochastycznymi, uznanymi już za klasykę metaheurystyki (np. SA, PSO, GA, CS, MFO, GWO, GSA), na temat których napisano setki artykułów i które poddano tysiącom testów. Proponowany algorytm może być z powodzeniem stosowany w różnych dziedzinach techniki i nauki. Charakteryzuje się wysoką skutecznością i szybkością w rozwiązywaniu różnych zadań optymalizacyjnych należących do różnych dziedzin. Ze względu na istnienie populacji cechuje go duża eksploracja przestrzeni poszukiwań. Nowe rozwiązania są zróżnicowane, co daje wysoką skuteczność w unikaniu lokalnych optimów. Uzyskane wyniki udowodniły jego wysoką wydajność i konkurencyjność wobec znanych metod rojowych.

Nowy algorytm przetestowano na problemach z zakresu mechaniki, matematycznych funkcjach testowych oraz zagadnieniach z elektroenergetyki. Na podstawie wyników tych testów można stwierdzić, że algorytm cechuje się następującymi właściwościami:

- niewielka liczba parametrów sterujących, brak powiązania ze szczególnymi właściwościami danego problemu (jest od niego niezależny) pozwala na szybkie dostosowanie go do większości zagadnień;
- czas obliczeń jest porównywalny z czasem uzyskania rozwiązania innymi metodami,
- z racji jego cech losowych, może być wykorzystywany do problemów nieliniowych, nieuporządkowanych,
- nadaje się do minimalizacji funkcji celu o dowolnym wymiarze,
- nadaje się do minimalizacji funkcji celu o wielu optimumach,
- możliwe jest zapamiętanie najlepszego dotychczas znalezionej rozwiązania,
- o wysokiej efektywności algorytmu świadczy fakt, że istnieje możliwość uzyskania rozwiązania przy jednym rozwiązaniu (strzale), w przeciwieństwie do innych metod, np. przeszukiwania kukułczanego, roju cząstek, algorytmów genetycznych, algorytmu śmy, które zazwyczaj wymagają minimalnej liczby odpowiednio kukulek, cząstek, agentów czy ciem równej 3 do 5.

Proponowany algorytm bardzo dobrze wypada na tle innych metod. Przetestowano dwadzieścia dwie matematyczne funkcje testowe, osiem zagadnień rzeczywistych z ograniczeniami z dziedziny mechaniki i dziesięć zagadnień rzeczywistych z ograniczeniami z dziedziny elektroenergetyki. Wyniki obliczeń porównano z wynikami obliczeń uzyskanymi innymi metodami, dostępnymi w literaturze. W wielu przypadkach, rezultaty uzyskane za pomocą algorytmu AIG są najlepsze.

Tym samym teza, przedstawiona w rozdziale 3 monografii, została udowodniona.

Najważniejszymi dokonaniem w przedstawionej monografii, w ocenie autora, są:

- przeprowadzenie pogłębionych studiów nad koniecznością poszukiwania nowych metod optymalizacji, które mogłyby być stosowane do rozwiązywania problemów nietypowych, dla których metody klasyczne nie dają oczekiwanych rezultatów,
- szczegółowy przegląd literatury światowej, dotyczący istniejących algorytmów optymalizacji klasycznej i heurystycznej,
- wykorzystywanie pełnych modeli sieci do obliczeń związanych z zagadnieniami optymalizacyjnymi w elektroenergetyce, w żadnych z rozpatrywanych przykładów nie było założeń upraszczających, typu np. linearyzacja,
- opracowanie nowej, autorskiej, uniwersalnej metody heurystycznej do rozwiązywania zadań optymalizacji,
- możliwość stosowania opracowanej metody do minimalizacji funkcji celu zagadnień w różnych dziedzinach nauki,
- możliwość stosowania opracowanej metody do minimalizacji funkcji celu o dowolnym wymiarze,

- możliwość stosowania opracowanej metody do minimalizacji funkcji celu o dowolnym kształcie,
- implementacja zaproponowanego algorytmu w środowisku Matlab,
- łączenie różnych programów obliczeniowych ze sobą, w celu wykorzystania ich możliwości, do osiągnięcia określonego celu,
- weryfikacja proponowanej metody i porównanie wyników z innymi algorytmami dla 40 różnych zagadnień,
- udowodnienie wysokiej skuteczności nowego algorytmu w rozwiązywaniu zadań optymalizacji w elektroenergetyce i nie tylko,
- stosunkowo szybkie znajdowanie rozwiązania za pomocą opracowanego algorytmu, bądź też zbliżanie się do punktu optymalnego, w porównaniu z innymi metodami.

W przyszłości, autor zamierza rozwinąć algorytm AIG do wersji wielokryterialnej, a także zwiększyć jego wydajność poprzez poszukiwanie innych funkcji aktualizacji wartości zmiennych. W kolejnym kroku będzie można zbadać wpływ parametrów sterujących na zbieżność algorytmu.

Bibliografia

1. Zhu J., *Optimization of power system operation*, Wiley-IEEE Press, 2015.
2. Amborski K., *Podstawy metod optymalizacji*, Wydawnictwo Politechniki Warszawskiej. Warszawa 2009.
3. Stachurski A., Wierzbicki A. P., *Podstawy optymalizacji*, WNT, Warszawa 2001.
4. Stadnicki J., *Teoria i praktyka rozwiązywania zadań optymalizacji*, WNT, Warszawa 2006.
5. Dommel H.W., Tinney W.F., *Optimal power flow solution*, IEEE Trans. On PAS. October 1968, s. 1866–1876.
6. Seidler J., Badach A., Molisz W., *Metody rozwiązywania zadań optymalizacji*, WNT, Warszawa 1980.
7. Findeisen W., Szymanowski J., Wierzbicki A., *Teoria i metody obliczeniowe optymalizacji*, WNT, Warszawa 1977.
8. Kremens Z., Sobierajski M., *Analiza systemów elektroenergetycznych*, WNT, Warszawa 1996.
9. Sadat H., *Power System Analysis*, McGraw-Hill, 1999.
10. Wenyu S., Ya-Xiang Y., *Optimization theory and methods. Nonlinear programming*, Springer, 2006.
11. Singiresu S. R., *Engineering Optimization. Theory and Practice*, John Wiley & Sons, INC, 2009, USA.
12. Luenberger D., G., Ye Y., *Linear and Nonlinear Programming*, Springer, 2008.
13. Bazaraa M., S., Jarvis J., J., Sherali H., D., *Linear Programming and Network Flows*, John Wiley & Sons, INC, 2010, USA.
14. Bazaraa M., S., Sherali H., D., Shetty C., M., *Nonlinear Programming. Theory and Algorithms*, John Wiley & Sons, INC, 2013, Canada.
15. Bhatti M., A., *Practical Optimization Methods. With Mathematica Applications*, Springer 1998.
16. Chong E., K., P., Żak S., H., *An Introduction to Optimization*, John Wiley & Sons, INC, 2001, USA.
17. Popov O., S., *Metody Numeryczne i Optymalizacja*, Politechnika Szczecińska, Szczecin 1999.
18. Horla D., *Metody obliczeniowe optymalizacji w zadaniach*, Poznań 2008.
19. Zhang B., *Control and optimization of power systems with renewables: voltage regulation and generator dispatch*, Technical Report No. UCB/EECS-2013-146, Electrical Engineering and Computer Sciences University of California at Berkeley, August 15, 2013.
20. Hogan W., W., Read E., G., Ring B., J., *Using mathematical programming for electricity spot pricing*, Int. Trans. Opl Res. Vol. 3, No. 3/4, pp. 209–221, 1996. Published by IFORS/Elsevier Science, Great Britain.
21. Michalewicz Z., Fogel D. B., *Jak to rozwiązać czyli nowoczesna heurystyka*, WNT, Warszawa 2006.

22. Michalewicz Z., Schouenauer M., *Evolutionary algorithms for constrained parameter optimization problems*, Evolutionary Computation, vol. 4, p. 1–32, 1996.
23. Bäck T., Hoffmeister F., Schwel H.P., *A Survey of evolution strategies*, Proceedings of the Fourth International Conference on Genetic Algorithms, Morgan Kaufmann, p. 2–9, 1991.
24. Homaifar A., Lai S.H.Y., Qi X., *Constrained optimization via genetic algorithms*, Simulation, vol. 62, p. 242–254, 1994.
25. Kuri Morales K., A., Quezada, C.C. A., *Universal eclectic genetic algorithm for constrained optimization*, Proceedings 6th European Congress on Intelligent Techniques & Soft Computing, EUFIT'98, p. 518–522, 1998.
26. Joines J., Houck C., *On the use of non-stationary penalty functions to solve non-linear constrained optimization problems with GAs*, Proceedings of the First IEEE International Conference on Evolutionary Computation, IEEE Press, p. 579–584, 1994.
27. Kazarlis S., Petridis V., *Varying fitness functions in genetic algorithms: studying the rate of increase in the dynamic penalty terms*, Proceedings of the 5th International Conference on Parallel Problem Solving from Nature, Berlin, Springer Verlag, p. 211–220, 1998.
28. Carlson Skalak S., Shonkwiler, R., Babar, S., Aral, M., *Annealing a genetic algorithm over constraints*, SMC 98 Conference, available from <http://www.math.gatech.edu/~shenk/body.html>.
29. Michalewicz Z., Attia N., *Evolutionary optimization of constrained problems*, Proceedings of the Third Annual Conference on Evolutionary Programming, World Scientific, p. 98–108, 1994.
30. Gen M., Cheng R. A., *Survey of penalty techniques in genetic algorithms*, Proceedings of the 1996 International Conference on Evolutionary Computation, IEEE, p. 804–809, 1996.
31. Hadj-Alouane A.B., Bean J.C., *A Genetic algorithm for the multiple-choice integer program*, Operations Research, vol. 45, p. 92–101, 1997.
32. Smith A., Tate D., *Genetic optimization using a penalty function*, Proceedings of the fifth International Conference on Genetic Algorithms, Morgan Kaufmann, p. 499–503, 1993.
33. Yokota T., Gen M., Ida K., Taguchi T., *Optimal design of system reliability by an improved genetic algorithm*, Electron. Commun. Jpn. 3, Fundam. Electron. Sci.79, p. 41–51, 1996.
34. Le Riche R., Knopf-Lenior C., Haftka R.T., *A Segregated genetic algorithm for constrained structural optimization*, Proceedings of the Sixth International Conference on Genetic Algorithms, Morgan Kaufmann, p. 558–565, 1995.
35. Coello C.A., *Use of a self-adaptive penalty approach for engineering optimization problems*, Computers in Industry, 41, p. 113–127, 2000.

36. Goldberg D.E., *Algorytmy genetyczne i ich zastosowania*. WNT, Warszawa 2003.
37. Michalewicz Z., Nazhiyath G., *GENOCOP III A Co-evolutionary algorithm for numerical optimization problems with nonlinear constraints*, Proceedings of the Second IEEE International Conference on Evolutionary Computation, IEEE Press, p. 647–651, 1995.
38. Deb K., *An Efficient constraint handling method for genetic algorithms*, Computer Methods in Applied Mechanics and Engineering, vol. 186, p. 311–338, 2000.
39. Powell D., Skolnick M.M., *Using genetic algorithms in engineering design optimization with non-linear constraints*, Proceedings of the Fifth International Conference on Genetic Algorithms, Morgan Kaufmann, p. 424–430, 1993.
40. Schouenauer M., Xanthakis S., *Constrained GA optimization*, Proceedings of the Fifth International Conference on Genetic Algorithms, Morgan Kaufmann, p. 473–580, 1993.
41. Michalewicz Z., Janikow C.Z., *Handling constraints in genetic algorithms*, Proceedings of the Fourth International Conference on Genetic Algorithms, Morgan Kaufmann, p. 151–157, 1993.
42. Koziel S. and Michalewicz Z., *Evolutionary algorithms, homomorphous mapping and constrained parameter optimization*, Evolutionary Computation, vol. 7, p. 19–44, 1999.
43. Schoenauer, M., Michalewicz, Z., *Evolutionary computation at the edge of feasibility*, Proceedings of the Fourth International Conference on Parallel Problem Solving from Nature, Springer Verlag, p. 22–27, 1996.
44. Adeli H., Cheng N.T., *Augmented lagrangian genetic algorithm for structural optimization*, Journal of Aerospace Engineering, vol. 7, p. 104–118, 1994.
45. Belur S.V., *CORE: Constrained optimization by random evolution*, Late Breaking Papers at the Genetic Programming Conference, Stanford University, p. 280–286, 1997.
46. Hajela P., Lee J., *Constrained genetic search via schema adaptation*, An immune network solution, Structural Optimization, vol. 12, p. 11–15, 1996.
47. Kim, J.H. and Myung, H., *Evolutionary programming techniques for constrained optimization problems*, IEEE Transaction on Evolutionary Computation, vol. 1, p. 129–140, 1997.
48. Le T.V., *Evolutionary approach to constrained optimization problems*, Proceedings of the Second IEEE International Conference on Evolutionary Computation, IEEE Press, p. 274–278, 1995.
49. Trojanowski K., *Metaheurystyki praktycznie*. Warszawa 2005.
50. Baczyński D., *Metody inteligencji obliczeniowej w elektroenergetyce*. WPW. Warszawa 2013.

51. Yang X.S., *Nature inspired metaheuristic algorithms*, United Kingdom 2010, Luniver Press.
52. Blum C., *Metaheuristics in Combinatorial Optimization: Overview and Conceptual Comparison*, ACM Computing Surveys, Vol. 35, No. 3, September 2003, p. 268–308.
53. Warren M., Pitts W., *A Logical Calculus of Ideas Immanent in Nervous Activity*, Bulletin of Mathematical Biophysics. 5 (4) 1943, p. 115-133.
54. Braspenning P.J., Thuijsman F., Weijters A. J. M. M., *Artificial Neural Networks, An Introduction to ANN Theory and Practice*, Springer, 1995.
55. Holland J. H., *Adaptation in natural and artificial systems*, University of Michigan Press, Ann Arbor, 1975.
56. Fogel L. J., Owens A. J., Walsh M. J., *Artificial Intelligence through Simulated Evolution*, New York: John Wiley, 1966.
57. Zadeh, Lotfi A., *Fuzzy sets*, Information and Control. 8 (3), p. 338–353, (1965). doi:10.1016/S0019-9958(65)90241-X.
58. Pedrycz W., *Fuzzy control and fuzzy systems*, (2 ed.), Research Studies Press Ltd.
59. Kirkpatrick S., Gelatt C. D., Vecchi M. P., *Optimization by Simulated Annealing*, Science, New Series, vol. 220, No. 4598. (May 13, 1983), p. 671–680.
60. Farmer J. D., Packard N., Perelson A., (1986) *The immune system, adaptation and machine learning*, Physica D, vol. 2, p. 187–204
61. Bersini H., Varela F. J., *Hints for adaptive problem solving gleaned from immune networks*, Parallel Problem Solving from Nature, First Workshop PPSW 1, Dortmund, FRG, October, 1990.
62. Dasgupta D. (Editor), *Artificial Immune Systems and Their Applications*, Springer-Verlag, Inc. Berlin, January 1999, ISBN 3-540-64390-7.
63. Eberhart R.C., Shi Y., *Particle swarm optimization: developments, applications and resources*, Proc. IEEE Int. Conf. on Evolutionary Computation, p. 81–86.
64. Eberhart R. C., Kennedy J., *A new optimizer using particle swarm theory*. Proc. Sixth Int. Symp. on Micromachine and Human Science, Nagoya, p. 39–43, 1995.
65. Colorni A., Dorigo M., Maniezzo V., *Distributed Optimization by Ant Colonies*, Actes de la première conférence européenne sur la vie artificielle, Paris, France, Elsevier Publishing, p. 134–142, 1991.
66. Dorigo M., *Optimization, Learning and Natural Algorithms*, PhD thesis, Politecnico di Milano, Italy, 1992.
67. Pham D.T., Ghanbarzadeh A., Koc E., Otri S., Rahim S. and Zaidi M., *The Bees Algorithm*. Technical Note, Manufacturing Engineering Centre, Cardiff University, UK, 2005.
68. Pham D. T., Ghanbarzadeh A., Koc E., Otri S., Rahim S., Zaidi M., *The Bees Algorithm – A Novel Tool for Complex Optimisation Problems*, in Proceedings of IPROMS 2006 Conference, 2006.

69. Geem, Zong Woo, Joong Hoon Kim, Loganathan G. V., *A new heuristic optimization algorithm: harmony search*, Simulation 76.2, p. 60–68, 2001.
70. Padberg M., *Harmony Search Algorithms for binary optimization problems*. Operations Research Proceedings. Operations Research Proceedings. 2011, p. 343–348. doi:10.1007/978-3-642-29210-1_55. ISBN 978-3-642-29209-5.
71. Reynolds R. G., *An Introduction to Cultural Algorithms*, in Proceedings of the 3rd Annual Conference on Evolutionary Programming, World Scientific Publishing, p. 131–139, 1994.
72. Reynolds R. G., *Cultural Algorithms: Theory and Applications*, New Ideas in Optimization, p. 367–378, McGraw-Hill Ltd., 1999.
73. Moscato, P., *On Evolution, Search, Optimization, Genetic Algorithms and Martial Arts: Towards Memetic Algorithms*, California Institute of Technology, 1989.
74. Chen, X. S.; Ong, Y. S.; Lim, M. H.; Tan, K. C., *A Multi-Facet Survey on Memetic Computation*. IEEE Transactions on Evolutionary Computation, vol. 15 (5), p. 591–607. doi:10.1109/tevc.2011.2132725.
75. Chen, X. S.; Ong, Y. S.; Lim, M. H., *Research Frontier: Memetic Computation – Past, Present & Future*. IEEE Computational Intelligence Magazine. 5 (2), p. 24–36. doi:10.1109/mci.2010.936309.
76. Niu, Ben, Wang, Hong, *Bacterial Colony Optimization*, Discrete Dynamics in Nature and Society, 2012. doi:10.1155/2012/698057.
77. Yang X. S., *Nature-Inspired Metaheuristic Algorithms*, Luniver Press 2008. ISBN 1-905986-10-6.
78. Yang X. S., *Nature-Inspired Metaheuristic Algorithms*, 2nd Edition, Luniver Press, 2010.
79. Yang X. S., *A New Metaheuristic Bat-Inspired Algorithm*, in: *Nature Inspired Cooperative Strategies for Optimization (NISCO 2010)*, Studies in Computational Intelligence, vol. 284, p. 65–74.
80. Glover F., *Future Paths for Integer Programming and Links to Artificial Intelligence*, Computers and Operations Research. 13 (5) 1986. p. 533–549. doi:10.1016/0305-0548(86)90048-1.
81. Glover F., *Tabu Search – Part 1*, ORSA Journal on Computing. 1 (2), p. 190–206, 1989. doi:10.1287/ijoc.1.3.190.
82. Glover F., *Tabu Search – Part 2*, ORSA Journal on Computing. 2 (1), p. 4–32, 1990, doi:10.1287/ijoc.2.1.4.
83. Yang X.S., Deb S., *Cuckoo search via Lévy flights*, World Congress on Nature & Biologically Inspired Computing (NaBIC 2009). IEEE Publications. p. 210–214.
84. Yang X.S., Deb S., *Eagle strategy using Levy walk and firefly algorithms for stochastic optimization*, Nature Inspired Cooperative Strategies for Optimization (NISCO 2010)} (Eds. J. R. Gonzalez et al.), vol. 284, p. 101–111 (2010).

85. Rabanal P., Rodríguez I., Rubio F., *Using River Formation Dynamics to Design Heuristic Algorithms*, Unconventional Computation, LNCS 4618, p. 163–177. Springer 2007.
86. Havens T., C., Spain C., J., Salmon N., G., Keller J., M., *Roach Infestation Optimization*, IEEE Swarm Intelligence Symposium, September 2008, p. 1–7.
87. Feng X., Lau F., C., M., Gao D., *A New Bio-inspired Approach to the Traveling Salesman Problem*, ICST Institute for Computer Sciences, Social Informatics and Telecommunications Engineering 2009, vol. 5, p. 1310–1321.
88. Monismith D., R., Mayfield B., E., *Slime Mold as a Model for Numerical Optimization*, in IEEE Swarm Intelligence Symposium, 2008.
89. Hosseini H., S., *Problem solving by intelligent water drops*, Evolutionary Computation, 2007. CEC 2007. IEEE Congress on, p. 3226–3231, 25–28 sept. 2007.
90. Eusuff M., M., Lansey K., E., *Optimization of Water Distribution Network Design Using the Shuffled Frog Leaping Algorithm*, Journal of Water Resources Planning and Management, vol. 129 (3) 2003, p. 210–225.
91. Mehrabian A., R., Lucas C., *A novel numerical optimization algorithm inspired from weed colonization*, Ecological Informatics, vol. 1 (4), 2006, p. 355–366.
92. Simon D., *Biogeography-based optimization*. IEEE Transactions on Evolutionary Computation, vol. 12 (6) 2008, p. 702–713.
93. Tamura K., Yasuda K., *Primary Study of Spiral Dynamics Inspired Optimization*, IEEE Transactions on Electrical and Electronic Engineering, vol. 6 (S1), p. 98–100, 2011.
94. Tamura K., Yasuda K., *Spiral Dynamics Inspired Optimization*, Journal of Advanced Computational Intelligence and Intelligent Informatics, vol. 132 (5) 2011, p. 1116–1121.
95. Wedyan A., Whalley J. N., *Hydrological Cycle Algorithm for Continuous Optimization Problems*. Journal of Optimization 2017, doi:10.1155/2017/3828420.
96. Rashedi E., Nezamabadi-Pour H., Saryazdi S., *A Gravitational Search Algorithm*. Information Sciences, vol. 179 (13), p. 2232–2248, doi:10.1016/j.ins.2009.03.004.
97. Yang Xin-She, *Flower Pollination Algorithm for Global Optimization*. Unconventional Computation and Natural Computation. Lecture Notes in Computer Science, vol. 7445. p. 240–249. doi:10.1007/978-3-642-32894-7_27.
98. Adel Sabry Eesa, A. M. A. B., Zeynep Orman, *Cuttlefish Algorithm – A Novel Bio-Inspired Optimization Algorithm*, International Journal of Scientific & Engineering Research, vol. 4(9) 2013, p. 1978–1986.
99. Eesa, Adel Sabry; Orman, Zeynep; Brifcani, Adnan Mohsin Abdulazeez, *A novel feature-selection approach based on the cuttlefish optimization algorithm for intrusion detection systems*. Expert Systems with Applications. 42 (5), 2015, p. 2670–2679.

100. Biyanto, Totok R; Matradji; Irawan, Sonny; Febrianto, Henokh Y; Afdanny, Naindar; Rahman, Ahmad H; Gunawan, Kevin S; Pratama, Januar A.D; Bethiana, Titania N. *Killer Whale Algorithm: An Algorithm Inspired by the Life of Killer Whale*. Procedia Computer Science, vol. 124, 2017, p. 151–157. doi:10.1016/j.procs.2017.12.141.
101. Biyanto, T. R., Matradji; Syamsi, M. N., Fibrianto H. Y.; Afdanny, N., Rahman A. H., Gunawan K. S., Pratama J. A. D., Malwindasari A., Abdillah A. I., Bethiana T. N., Putra Y. A., *Optimization of Energy Efficiency and Conservation in Green Building Design Using Duelist, Killer-Whale and Rain-Water Algorithms*. IOP Conference Series: Materials Science and Engineering, vol. 267, 2017, 012036, p. 1–8.
102. Mirjalili S., *Moth-flame optimization algorithm: A novel nature-inspired heuristic paradigm*, Knowledge-Based Systems 89 (2015), p. 228–249.
103. Dai C., Zhu Y., Chen W., *Seeker optimization algorithm*, in: *Computational Intelligence and Security*, Springer, 2007, p. 167–176.
104. Salcedo-Sanz S., Pastor-Sánchez A., Gallo-Marazuela D., Portilla-Figueras A., *A novel coral reefs optimization algorithm for multi-objective problems*, in: *Intelligent Data Engineering and Automated Learning – IDEAL 2013*, vol. 8206, H. Yin, K. Tang, Y. Gao, F. Klawonn, M. Lee, T. Weise, et al. (Eds.), Springer, Berlin Heidelberg, 2013, p. 326–333.
105. Moosavian N., Kasaei Roodsari B., *Soccer league competition algorithm: a novel meta-heuristic algorithm for optimal design of water distribution networks*, Swarm Evol. Comput. 17, 2014, p. 14–24.
106. Cheng M.-Y., Prayogo D., *Symbiotic organisms search: a new metaheuristic optimization algorithm*, Comput. Struct. 139 (2014), p. 98–112.
107. Sadollah A., Bahreininejad A., Eskandar H., Hamdi M., *Mine blast algorithm: a new population based algorithm for solving constrained engineering optimization problems*, Appl. Soft Comput. 13, 2013, p. 2592–2612.
108. Formato R. A., *Central force optimization: a new nature inspired computational framework for multidimensional search and optimization*, in: *Nature Inspired Cooperative Strategies for Optimization (NISCO 2007)*, Springer, 2008, p. 221–238.
109. Hatamlou A., *Black hole: a new heuristic optimization approach for data clustering*, Inf. Sci., vol. 222, 2013, p. 175–184.
110. Kaveh A., Khayatatzad M., *A new meta-heuristic method: ray optimization*, Comput. Struct., vol. 112–113, 2012, p. 283–294.
111. Kaveh A., Talatahari S., *A novel heuristic optimization method: charged system search*, Acta Mech., vol. 213, 2010, p. 267–289.
112. Lam A. Y., Li V. O., *Chemical-reaction-inspired metaheuristic for optimization*, IEEE Trans. Evol. Comput. 14, 2010, p. 381–399.
113. Alatas B., *A novel chemistry based metaheuristic optimization method for mining of classification rules*, Expert Syst. Appl., vol. 39, 2012, p. 11080–11088.

114. Oftadeh R., Mahjoob M. J., Shariatpanahi M., *A novel meta-heuristic optimization algorithm inspired by group hunting of animals: hunting search*, Comput. Math. Appl., vol. 60, 2010, p. 2087–2098.
115. Kaveh A., Farhodi N., *A new optimization method: Dolphin echolocation*, Adv. Eng. Softw., vol. 59, 2013, p. 53–70.
116. Mirjalili S., Mirjalili S. M., Lewis A., *Grey wolf optimizer*, Adv. Eng. Softw., vol. 69 (2014), p. 46–61.
117. Pan W. T., *A new fruit fly optimization algorithm: taking the financial distress model as an example*, Knowl.-Based Syst., vol. 26, 2012, p. 69–74.
118. Abdechiri M., Meybodi M. R., Bahrami H., *Gases Brownian motion optimization: an algorithm for optimization (GBMO)*, Appl. Soft Comput., vol. 13, 2013, p. 2932–2946.
119. Cuevas E., Echavarría A., Ramírez-Ortegón M.A., *An optimization algorithm inspired by the states of matter that improves the balance between exploration and exploitation*, Appl. Intell., vol. 40, 2014, p. 256–272.
120. Gaston K. J., Bennie J., Davies T. W., Hopkins J., *The ecological impacts of nighttime light pollution: a mechanistic appraisal*, Biol. Rev., vol. 88, 2013, p. 912–927.
121. Wang G. G., Guo L., Gandomi A. H., Hao G.-S., Wang H., *Chaotic krill herd algorithm*, Inf. Sci., vol. 274, 2014, p. 17–34.
122. Krishnanand K., Ghose D., *Glowworm swarm optimisation: a new method for optimising multi-modal functions*, Int. J. Comput. Intell. Stud., vol. 1, 2009, p. 93–119.
123. Karaboga, D., *An Idea Based on Honey Bee Swarm For Numerical Optimization*. TECHNICAL REPORT-TR06, OCTOBER, 2005. Erciyes University, Engineering Faculty Computer Engineering Department Kayseri/Türkiye.
124. Atashpaz-Gargari E.; Lucas C. *Imperialist competitive algorithm: An algorithm for optimization inspired by imperialistic competition*. 2007 IEEE Congress on Evolutionary Computation (CEC 2007), p. 4661–4667, doi:10.1109/CEC.2007.4425083.
125. Seyedmohsen H., Al Khaled A. (2014). *A survey on the Imperialist Competitive Algorithm metaheuristic: Implementation in engineering domain and directions for future research*. Applied Soft Computing 24, 2015, p. 1078–1094, doi:10.1016/j.asoc.2014.08.024.
126. Rosenberg L., *Artificial Swarm Intelligence, a Human-in-the-loop approach to A.I.* Proceedings of the 13th Annual AAAI Conference on Artificial Intelligence (AAAI-16), p. 4381–4382, February 12, 2016.
127. Biyanto, Totok Ruki; Fibrianto, Henokh Yernias; Nugroho, Gunawan; Hatta, Agus Muhamad; Listijorini, Erny; Budiati, Titik; Huda, Hairul. *Duelist Algorithm: An Algorithm Inspired by How Duelist Improve Their Capabilities in a Duel*. Advances in Swarm Intelligence. Lecture Notes in Computer Science, 2016, LNCS 9712. p. 39–47. doi:10.1007/978-3-319-41000-5_4.

128. Liu C., Han M., Wang X., *A novel evolutionary membrane algorithm for global numerical optimization*, in: 2012 Third International Conference on Intelligent Control and Information Processing (ICICIP), 2012, p. 727–732.
129. Montiel O., Castillo O., Melin P., Díaz A.R., Sepúlveda R., *Human evolutionary model: a new approach to optimization*, Information Sciences., vol. 117, Issue 10, 15 May 2007, p. 2075–2098.
130. Farasat A., Menhaj M.B., Mansouri T., Moghadam M.R.S., *ARO: a new model free optimization algorithm inspired from asexual reproduction*, Appl. Soft Comput., vol. 10, issue 4, September 2010, p. 1284–1292.
131. Bernas S., *Systemy elektroenergetyczne*. WNT, Warszawa 1986.
132. Gładyś H., Matla R., *Praca elektrowni w systemie elektroenergetycznym*. WNT, Warszawa 1999.
133. Kacejko P., Pijarski P., *Możliwości podziału kosztów modernizacji na jednostki wytwórcze ubiegające się o przyłączenie*. Przegląd Elektrotechniczny, nr 9a, vol. 88, 2012, s. 27–31.
134. Kacejko P., Pijarski P., Robak S., Sobierajski M., *Ocena możliwości przyłączeniowych węzłów systemu elektroenergetycznego. Część III – nieliniowa optymalizacja generacji wiatrowej*. Rynek Energii – 2012, nr 3 (100), vol. 100, s. 44–52.
135. Kacejko P., Pijarski P., *Wykorzystanie metod symulowanego wyżarzania i roju cząsteczek do optymalizacji rozptywu mocy biernej w sieciach elektroenergetycznych*, II Konferencja Naukowo-Techniczna Problematyka Mocy Biernej w Sieciach Dystrybucyjnych i Przesyłowych, 24–25 października 2012, Wisła 2012, s. 1–9.
136. Kacejko P., Pijarski P., Miller P., *Assessment of wind farm potential regarding voltage control over extensive 110 kV network system areas*, in: *Safety of the polish power system*, [red:] Demenko Andrzej, Lorenc Józef, Scientific Publishers OWN, Poznań 2012, ISBN 978-83-7712-072-9.
137. Kacejko P., Pijarski P., *Ocena możliwości przyłączeniowych krajowej sieci przesyłowej planowanej na lata 2020–2025 w kontekście prawdopodobnych scenariuszy budowy nowych jednostek wytwórczych*. Rynek Energii – 2013, nr 2 (105), vol. 105, s. 42–47.
138. Kacejko P., Pijarski P., *Dopasowanie poziomu mocy generowanej do możliwości przesyłowych linii elektroenergetycznych*, in: *Zeszyty naukowe Wydziału Elektrotechniki i Automatyki Politechniki Gdańskiej*, Gdańsk 2013, nr 32, s. 11–14.
139. Kacejko P., Pijarski P., *Generation Level Matching to the Transmission Capability of Overhead Lines*. Acta Energetica, vol. 1/14 (2014), s. 43–49.
140. Kacejko P., Pijarski P., *Optymalizacja kosztów bilansowania systemu elektroenergetycznego przy wykorzystaniu metod heurystycznych*. Przegląd Elektrotechniczny, nr 4, vol. 90, 2014, s. 28–31. doi: 10.12915/pe.2014.03.07.

141. Kacejko P., Pijarski P.: *Wykorzystanie metod optymalizacji heurystycznej do minimalizacji kosztów bilansowania systemu elektroenergetycznego*. Przegląd Elektrotechniczny, nr 4, vol. 90, 2014, s. 165–168.
doi: 10.12915/pe.2014.04.38. ISSN 0033-2097.
142. Pijarski P., Rzepecki A., Wydra M., *Efektywne zarządzanie mocą farm wiatrowych*. Rynek Energii – 2014, nr 2 (111), vol. 111, s. 69–74.
143. Kacejko P., Pijarski P., Gałązka K., *Prosument – przyjaciel, wróg czy tylko hobbysta ?* Rynek Energii – 2014, nr 5 (114), vol. 114, str. 83–89.
144. Kacejko P., Pijarski P., *Zmiana rozkładu generacji w warunkach wystąpienia awaryjnych przeciążeń sieci przesyłowej*. Blackout a Krajowy System Elektroenergetyczny, Edycja 2014, s. 225–235. Poznań 2014.
145. Kacejko P., Pijarski P., Gałązka K., *Prosument – krajobraz po bitwie*. Rynek Energii – 2015, nr 2, vol. 117, s. 40–44.
146. Kacejko P., Pijarski P., Adamek S., *Compensation of 110kV cable lines-possibilities and limitation*. ActaEnergetica 3/2015, s. 26–33.
147. Montusiewicz J., Gryniiewicz_Jaworska M., Pijarski P., *Looking for the optimal location for wind farms*. Advances in science and technology research journal. Nr 27 (2015), vol. 9, s. 135–142.
148. Pijarski P., Gryniiewicz_Jaworska M., *Optimization in the electric power engineering – problems and challenges*, in: *Teka komisji motoryzacji i energetyki rolnictwa PAN*, nr. 4 (2015), vol. 15, s. 143–148.
149. Kacejko P., Pijarski P., Wydra M., *Możliwość likwidacji przeciążeń linii KSE przy wykorzystaniu systemu dynamicznego zarządzania zdolnościami przesyłowymi (SDZP)*. Optymalizacja w elektroenergetyce: IX Konferencja Naukowo-Techniczna, Optymalizacja w elektroenergetyce. Konstancin Jeziorna 2015, s. 59–68.
150. Pijarski P., Gryniiewicz_Jaworska M., *Dobór urządzeń kompensacyjnych dla farmy wiatrowej przyłączonej do sieci 110 kV*. Informatyka, automatyka, pomiary w gospodarce i ochronie środowiska, nr 1 (2016), s. 47–50.
151. Kacejko P., Pijarski P.: *Zarządzanie mikroinstalacjami OZE – realne wyzwanie techniczne, czy tylko impuls marketingowy?* Rynek Energii – 2016, Nr 1, vol. 122, s. 41–45.
152. Gałązka K., Kacejko P., Pijarski P., *Wykluczeni - jednostki sektora finansów publicznych na straconej pozycji wśród wytwórców OZE?* Rynek Energii – 2016, Nr 2, vol. 123, s. 40–45.
153. Jędrzychowski R., Pijarski P., Adamek S.: *Monitorowanie wpływu mikroinstalacji prosumenckich na parametry elektryczne sieci nN*. Rynek energii elektrycznej: energetyka rozproszona. Politechnika Lubelska, 2016, s. 53–61.
154. Pijarski P., Kacejko P., Wancierz M., Gryniiewicz_Jaworska M., *Układ sterowania mocą bierną farmy wiatrowej wykorzystujący możliwości regulacyjne przekształtników, dławika zaczepowego oraz pojemność kabla zasilającego farmę*. Przegląd Elektrotechniczny, nr 8, 2016, s. 44–47.
doi: 10.15199/48.2016.08.12.

155. Burbelo M. J., Pijarski P., Zavadskiy V., Koczorowska-Gazda A., Lyudmyla M., Melnychuk L. M., Loboda Y. V., *Measurement of reactive power under asymmetrical nonsinusoid modes of electric networks with earthed neutral*. Proceedings of SPIE, ISSN 0277-786X; nr 10031. 28 September, 2016. doi: 10.1117/12.2248788.
156. Jędrychowski R., Pijarski P., Adamek S., Sereja K., *Korzyści ekonomiczne z zastosowania zasobnika energii w sieci niskiego napięcia*. Rynek Energii – 2017, nr 1, vol. 128, s. 31–34.
157. Pijarski P., Koczorowska-Gazda A., *Znaczenie importu dla rynku mocy – doświadczenia rynków amerykańskich*. Rynek Energii – 2017, nr 1, vol. 128, s. 23–30.
158. Kacejko P., Pijarski P., Gałązka K., *Ile powinien kosztować magazyn energii?* Rynek Energii – 2017, nr 2, vol. 129, s. 51–55.
159. Jędrychowski R., Pijarski P., Adamek S., *Wykorzystanie zasobnika energii do regulacji parametrów elektrycznych w sieci niskiego napięcia*. Rynek Energii – 2017, nr 2, vol. 129, s. 56–59.
160. Kacejko P., Pijarski P., Wydra M., Nowak W., Kmak J., Szpyra W., Tarko R., *System dynamicznego zarządzania zdolnościami przesyłowymi w systemach elektroenergetycznych*, in: *Zeszyty naukowe Wydziału Elektrotechniki i Automatyki Politechniki Gdańskiej*, nr 53, Gdańsk 2017, s. 107–110.
161. Perekest A., Shendryk V., Pijarski P., Parfenenko Y., Shendryk S., *Complex information and technical solutions for energy management of municipal energetics*, Proceedings of SPIE, ISSN 0277-786X; nr 10445, 07.08.2017. doi: 10.1117/12.2280962.
162. Lezhniuk P. D., Pijarski P., Buslavets O.A., *Smart grid technologies in local electric grids*. Proceedings of SPIE, ISSN 0277-786X; nr 10445, 07.08.2017. doi: 10.1117/12.2280957.
163. Pijarski P., Gryniewicz-Jaworska M., *Problems of reactive power compensation of 110 kV line cable*. MATTER: International Journal of Science and Technology, vol. 3, Issue 3, p. 163–172. DOI-<https://dx.doi.org/10.20319/mijst.2017.32.163172>.
164. Pijarski P., Kacejko P., Gałązka K., Gryniewicz-Jaworska M., *Issues of reactive power management in distributed energy sources*. ActaEnergetica 3/2017, vol. 32, s. 176–181.
165. Kacejko P., Pijarski P., *Mitigation of Voltage Rise Caused by Intensive PV Development in LV Grid*. The 7th International Workshop on the Integration of Solar Power into Power Systems: proceedings, 24–25 October 2017. Berlin, p. 381–385.
166. Pijarski P., Kacejko P., *A new metaheuristic optimization method – the algorithm of the Innovative Gunner (AIG)*, Engineering Optimization, doi: 10.1080/0305215X.2019.1565282, 22 Jan 2019.

167. Szpyra W., Kacejko P., Pijarski P., Wydra M., Kmak R., Nowak W., Tarko R., *Dynamic management of transmission capacity in power systems*. ActaEnergetica, nr 4/2017, vol. 33, s. 68–77.
168. Pijarski P., Kacejko P., *Methods of Simulated Annealing and Particle Swarm Applied to the Optimization of Reactive Power Flow in Electric Power Systems*, Advances in Electrical and Computer Engineering, vol. 18, no. 4, p. 43–48, doi: 10.4316/AECE.2018.04005.
169. Pijarski P., Wydra M., Kacejko P., *Optimal Control of Wind Power Generation*. Advances in Science and Technology Research Journal, vol. 12, Issue 1, 2018, p. 9–18, DOI: 10.12913/22998624/81448.
170. Zdun Z., *Algorytmy podstawowych obliczeń systemów elektroenergetycznych*. Wydawnictwo Politechniki Warszawskiej, Warszawa 1979.
171. Pijarski P., *Algorytm dynamicznego dopasowania poziomu mocy generowanej do możliwości przesyłowych linii elektroenergetycznych*. Rozprawa doktorska. Politechnika Lubelska 2011.
172. Balas E., *Discrete programming by the filter method*. Operations Research 1967, vol. 15, p. 915–957.
173. Balas E., *An additive algorithm for solving linear programs with zero/one variables*. Operations Research 1965, vol. 13, p. 517–546.
174. Sawik T., *Badania operacyjne dla inżynierów zarządzania*. Kraków, Wyd. AGH 1998.
175. Sysło M., Deo N., Kowalik J., *Algorytmy optymalizacji dyskretniej*. Warszawa, PWN 1995.
176. Kozieł S., Michalewicz Z., *A decoder-based evolutionary algorithm for constrained parameter optimization problems*. PPSN 1998: Parallel Problem Solving from Nature — PPSN, p. 231–240.
177. Wang Q. He, L., *An effective co-evolutionary particle swarm optimization for constrained engineering design problems*, Eng. Appl. Artif. Intell. 20, 2007, p. 89–99.
178. Mezura-Montes E., Coello C. A. C., *An empirical study about the usefulness of evolution strategies to solve constrained optimization problems*, Int. J. Gen. Syst. 37, 2008, p. 443–473.
179. Kannan, B. K., Kramer, S.N., *An augmented Lagrange multiplier based method for mixed integer discrete continuous optimization and its applications to mechanical design*. Transactions of the ASME, Journal of Mechanical Design 116, 1994, p. 318–320.
180. Coello C.A., *Use of a self-adaptive penalty approach for engineering optimization problems*, Comput. Ind. 41, 2000, p. 113–127.
181. Coello C. A., Mezura Montes E., *Constraint-handling in genetic algorithms through the use of dominance-based tournament selection*, Adv. Eng. Inform. 16, 2002, p. 193–203.
182. Rao, S.S., *Engineering Optimization. Theory and practice*. Wiley, New York, 2009.

183. Chickermane H., Gea H., *Structural optimization using a new local approximation method*, Int. J. Numer. Methods Eng., vol. 39, 1996, p. 829–846.
184. Mezura-Montes E., Coello C.A.C., *Useful infeasible solutions in engineering optimization with evolutionary algorithms*, in: MICAI 2005: Lect. Notes Artif. Int., vol. 3789, 2005, p. 652–662, http://dx.doi.org/10.1007/11579427_66.
185. Kuang J.K., Rao S.S., Chen L., *Taguchi-aided search method for design optimization of engineering systems*, Engineering Optimization, vol. 30 (1998), p. 1–23.
186. M. Zhang, W. Luo, X. Wang, *Differential evolution with dynamic stochastic selection for constrained optimization*, Information Sciences, vol. 178 (2008), p. 3043–3074.
187. Molga M., Smutnicki C., *Test functions for optimization needs*, Test Funct. Opt. Needs 2005.
188. Digalakis J., Margaritis K., *On benchmarking functions for genetic algorithms*, Int. J. Comput. Math. 77, 2001, p. 481–506.
189. Jamil M., Yang X-S., Zepernick H-J., *Test Functions for Global Optimization: A Comprehensive Survey*, Swarm Intelligence and Bio-Inspired Computation, 2013, p. 193–222, doi: <http://dx.doi.org/10.1016/B978-0-12-405163-8.00008-9>.
190. Jamil M., Yang X-S., *A Literature Survey of Benchmark Functions For Global Optimization Problems*, Int. Journal of Mathematical Modelling and Numerical Optimisation, vol. 4, No. 2, p. 150–194 (2013), doi: 10.1504/IJMMNO.2013.055204.
191. Kacejko P., Pijarski P., Miller P., *Oszacowanie wielkości mocy źródeł energii elektrycznej możliwych do przyłączenia do węzłów w Krajowym Systemie Przesyłowym*. Praca wykonana na zlecenie PSE Operator S.A pod kierownictwem prof. M. Sobierajskiego. Politechnika Wrocławska 2010.
192. Robak S., Rasolomampionona D., Kacejko P., Sobierajski M., *Ocena Możliwości przyłączeniowych węzłów systemu elektroenergetycznego. Część I – wymagania i założenia*. Rynek Energii, nr 1 (98), 2012, s. 11–16.
193. Sobierajski M., Kacejko P., Robak S., *Ocena Możliwości przyłączeniowych węzłów systemu elektroenergetycznego. Część II – Liniowa optymalizacja generacji wiatrowej*. Rynek Energii, nr 2, 2012, s. 55–63.
194. Kacejko P., Pijarski P., Miller P., Wancerz M., Adamek S., Rzepecki A., Wydra M., *Optymalizacja gospodarki mocą bierną w Krajowym Systemie Elektroenergetycznym. Część I: Analizy techniczne – wybór metody/metod optymalizacji gospodarki mocą bierną*. Praca wykonana na zlecenie PTPiREE pod kierownictwem prof. K. Wilkosza. Politechnika Wrocławska 2012.
195. Hazarika D., Sinha A. K., *Standing phase-angle reduction for power system restoration*. IEE Proc.-Gener. Transm., Distr., Vol. 145, N. 1, 1998
196. Hazarika D., Sinha A. K.: *An algorithm for standing phase angle reduction for power system restoration*. IEEE Transactions on Power Systems, vol. 14, No. 4, 1999.

197. Kacejko P., Machowski J., Wancierz M., Adamek S., Miller P., *Opracowanie metody oraz narzędzi do oceny parametrów łączń synchronicznych elementów sieci przesyłowej w oparciu o przebiegi symulacji dynamicznych*. Praca B+R nr Nr 4/ WEiIPL/IF/2010/RB/TK wykonana na zlecenie PSE Operator, Politechnika Lubelska, 2011r.
198. Ketabi A., Ranjbar A.M., Feuillet R., *New approach to standing phase angle reduction for power system restoration*. ETEP vol. 12, no. 4, July/August 2002.
199. Machowski J., Kacejko P., Miller P., *Udary prądowe przy zamykaniu pierścieni sieciowych w sieci przesyłowej wysokiego napięcia*. Przegląd Elektrotechniczny, nr 8, 2011.
200. Martins N., Edimar José de Oliveira, Weberson Carvalho Moreira, José Luiz Rezende Pereira, Rafael Montes Fontoura. Redispatch to reduce rotor shaft impacts upon transmission loop closure, IEEE Transactions on Power Systems, vol. 23, No. 2, May 2008.
201. Nourizadeh Saber, Ranjbar, Pishvaei Mahmoud R., *Standing phase angle reduction based on a wide area monitoring system using genetic algorithm*. International Journal of Emerging Electric Power Systems, vol. 11, issue 3, 2010.
202. Shahidehpour S.M., H.Y.Yamin, *A technique for the standing phase-angle reduction in power system restoration*. Electric Power Components and Systems, 33, p. 277–286, 2005.
203. Wunderlich S., Adibi M.M., Fischl R., Nwankpa C.O.D., *An approach to standing phase angle reduction*, IEEE Transactions on Power Systems, vol. 93, no. 1, February 1994.
204. Yuan Rongxiang, Ling Junyin, Zhang Zhiyi, Ruan Yang, Sheng Yong, *A genetic algorithm for standing phase angle reduction in power system restoration*, 978-1-4244-6551-4/10, 2010.
205. Rao R.V., Savsani V.J., Vakharia D.P., *Teaching-learning-based optimization: a novel method for constrained mechanical design optimization problems*, Computer-Aided Design 43 (2011), p. 303–315.
206. Rao R.V., Patel V., *An elitist teaching-learning-based optimization algorithm for solving complex constrained optimization problems*, International of Industrial Engineering Computations 3 (2012), p. 535–560.
207. Rao R.V., Patel V., *Multi-objective optimization of heat exchangers using a modified teaching-learning-based-optimization algorithm*, Applied Mathematical Modelling, 2012, <http://dx.doi.org/10.1016/j.apm.2012.03.043>.
208. Ray T., Liew K.M., *Society and civilization: an optimization algorithm based on the simulation of social behavior*, IEEE Transactions on Evolutionary Computation 7 (2003), p. 386–396.
209. Mann F.W., *The bullets flight from powder to target*, New York, Munn and Co Publishers, 1909.
210. EN 50438, *Requirements for the connection of micro-generators in parallel with public low-voltage distribution networks*.

211. AS/NZS 4777.2, 2015 – *Grid Connection of Energy Systems via Inverters, Part 2 – Inverter Requirements*.
212. Instrukcja Ruchu i Eksploatacji Sieci Przesyłowej, www.pse.pl.
213. Rozporządzenie Komisji (UE) 2016/631 z dnia 14 kwietnia 2016 r. ustanawiające kodeks sieci dotyczący wymogów w zakresie przyłączenia jednostek wytwórczych do sieci, Dziennik Urzędowy UE L112 z 2016 r.
214. Taryfa dla usług dystrybucji energii elektrycznej PGE Dystrybucja S.A. na rok 2018, <https://pgedystrybucja.pl/Dla-Klienta/Taryfy-i-cenniki>.
215. <http://www.kios.uci.ac.cy/testsystems/index.php/dynamic-ieee-test-systems/ieee-118-bus-modified-test-system> [dostęp: wrzesień 2018].
216. <https://electricgrids.engr.tamu.edu/electric-grid-test-cases/ieee-96-rtts-test-system/> [dostęp: wrzesień 2018].
217. Korab R., *Optymalizacja operatorstwa przesyłowego w krajowym systemie elektroenergetycznym*. Wydawnictwo Politechniki Śląskiej, Gliwice 2011.
218. <https://www.powerworld.com/> [dostęp: wrzesień 2018].
219. <https://www.mathworks.com/> [dostęp: wrzesień 2018].
220. Bracken J., McCormick G. P., *Selected Applications of Nonlinear Programming*, John Wiley & Sons, New York, 1968.
221. Homaifar A., Qi C. X., Lai S. H., *Constrained optimization via genetic algorithms*, Simulation 62 (1994), p. 242–253.
222. Fogel D. B., *A comparison of evolutionary programming and genetic algorithms on selected constrained optimization problems*, Simulation vol. 64, 1995, p. 397–404.
223. Lee K. S., Geem Z. W., *A new meta-heuristic algorithm for continuous engineering optimization: harmony search theory and practice*, Computer Methods in Applied Mechanics and Engineering, vol. 194, 2005, p. 3902–3933.
224. Chootinan P., Chen A., *Constraint handling in genetic algorithms using a gradient-based repair method*, Computers & Operations Research 33, 2006, p. 2263–2281.
225. Faris H., Al-Zoubi Ala' M., Heidari A., A., Aljarah I., Mafarja M., Hassonah M., A., Fujita H., *An intelligent system for spam detection and identification of the mostlevant features based on evolutionary Random Weight Networks*. Information Fusion, doi: 10.1016/j.inffus.2018.08.002.
226. Mafarja M., Aljarah I., Heidari A., A., Hammouri H., I., Faris H., Al-Zoubi Ala' M., Mirjalili S., *Evolutionary Population Dynamics and Grasshopper Optimization approaches for feature selection problems*. Knowledge-Based Systems, vol. 145, April 2018, p. 25–45.
227. Mirjalili S., Gandomi A. H., Mirjalili S. Z., Saremi S., Faris H., Mirjalili S. M., *Salp swarm algorithm: A bio-inspired optimizer for engineering design problems*, Adv. Eng. Software, vol. 114, December 2017, p. 163–191.
228. Faris H., Mafarja M., Heidari A. A., Aljarah I., Al-Zoubi Ala' M., Mirjalili S., Fujita H., *An efficient binary Salp Swarm Algorithm with crossover scheme for feature selection problems*. Knowledge-Based Systems, vol. 154, August 2018, p. 43–67.

229. Heidari A., A., Abbaspour R., A., Jordehi A., R., *Efficient chaotic water cycle algorithm for optimization tasks*. Neural Computing and Applications. vol. 28, January 2017, p. 57–85.
230. Wolpert D.H., Macready W.G., *No free lunch theorems for optimization*. Evolut Comput, IEEE Trans 1997, vol.1, p. 67–82.
231. Faris H., Aljarah I., Mirjalili S., *Improved monarch butterfly optimization for unconstrained global search and neural network training*. Appl Intell 48 (2), p. 445–64. doi:10.1007/s10489-017-0967-3.
232. Heidari A. A., Rahim A. A., *Enhanced Chaotic Grey Wolf Optimizer for Real-World Optimization Problems*, In Handbook of Research on Emergent Applications of Optimization Algorithms. vol. 111, edited by Madjid Tavana, Pandian Vasant, Sirma Z. Alparslan-Gok, and Gerhard-Wilhelm Weber, p. 693–727. Advances in Business Information Systems and Analytics: IGI Global.
233. Heidari, A. A., Faris H., Aljarah I., Mirjalili S., *An efficient hybrid multilayer perceptron neural network with grasshopper optimization*. Soft Computing 22 (7), p. 1–18, July 2018, doi:10.1007/s00500-018-3424-2.
234. Heidari, A. A., Parham Pahlavani P., *An efficient modified grey wolf optimizer with Lévy flight for optimization tasks*. Applied Soft Computing, vol. 60, November 2017, p. 115–34.
235. Majdi M., Aljarah I., Heidari A., A., Faris H., Fournier-Viger P., Li X., Mirjalili S. 2018a. *Binary dragonfly optimization for feature selection using time-varying transfer functions*. Knowledge-Based Systems. August 2018, doi:10.1016/j.knosys.2018.08.003.
236. Aljarah I., Faris H., Mirjalili S., *Optimizing connection weights in neural networks using the whale optimization algorithm*, Soft Computing, vol. 22 (1), 2018, p. 1–15.
237. Das A.K., Das S., Ghosh A., *Ensemble feature selection using bi-objective genetic algorithm*, Knowledge Based Systems, vol. 123, 2017, p. 116–127.
238. Zainuddin Z., Lai K.H., Ong P., *An enhanced harmony search based algorithm for feature selection. Applications in epileptic seizure detection and prediction*, Comput. Electr. Eng., vol. 53, 2016, p. 143–162.
239. Aljarah I., Majdi M., Ali A. Faris H., Zhang Y, Mirjalili S., 2018. *Asynchronous accelerating multi-leader salp chains for feature selection*. Applied Soft Computing, vol. 71, p. 964–979.
240. Sree R., K., S., Murugan S., *Memory based Hybrid Dragonfly Algorithm for numerical optimization problems*. Expert Systems with Applications, vol. 83, p. 63–78.
241. Majdi M., and Seyedali Mirjalili S., *Hybrid binary ant lion optimizer with rough set and approximate entropy reducts for feature selection*. Soft Comput, vol. 57 (1), p. 1–17. doi:10.1007/s00500-018-3282-y.

242. Yu-Peng Ch., Li Y., Wang G, Zheng Y., Xu Q., Fan J., Cui X., *A novel bacterial foraging optimization algorithm for feature selection*. Expert Systems with Applications, vol. 83, p. 1–17.
243. Awad, N. H., Ali M. Z., Suganthan, P. N., Liang, J. J., Qu, B., Y., eds. 2016. *Problem Definitions and Evaluation Criteria for the CEC 2017 Special Session and Competition on Single Objective Real-Parameter Numerical Optimization*: Technical Report, Nanyang Technological University, Singapore And Jordan University of Science and Technology, Jordan And Zhengzhou University, Zhengzhou China.
244. Miller P., *Synchroniczne i asynchroniczne operacje łączeniowe w systemie elektroenergetycznym*. Politechnika Lubelska, Lublin, 2013.



ISBN: 978-83-7947-349-6

