

Instytut Energoelektryki
Zakład Sieci i Systemów Elektroenergetycznych

Robert Łukomski

Weryfikacja topologii systemu
elektroenergetycznego
z wykorzystaniem
sztucznych sieci neuronowych

Praca doktorska
przygotowana pod kierunkiem:
dr. hab. inż. Kazimierza Wilkosza, prof. nadzw. PWr

Wrocław 2002

Spis treści

1. WPROWADZENIE	4
2. CEL, TEZA I ZAKRES ROZPRAWY	7
3. TOPOLOGIA SYSTEMU ELEKTROENERGETYCZNEGO	9
3.1. WPROWADZENIE	9
3.2. OKREŚLANIE TOPOLOGII SYSTEMU ELEKTROENERGETYCZNEGO	9
3.3. BŁĘDY TOPOLOGII SYSTEMU ELEKTROENERGETYCZNEGO	10
3.4. PRZYCZYNY POWSTAWANIA BŁĘDÓW TOPOLOGII.....	11
3.5. POJĘCIE WERYFIKACJI TOPOLOGII SYSTEMU ELEKTROENERGETYCZNEGO	11
3.6. KLASYFIKACJA PODEJŚĆ DO WERYFIKACJI TOPOLOGII SYSTEMU ELEKTROENERGETYCZNEGO	12
3.7. PRZEGLĄD METOD WERYFIKACJI TOPOLOGII SYSTEMU ELEKTROENERGETYCZNEGO	12
3.7.1. <i>Metody wykorzystujące wyniki estymacji stanu</i>	<i>12</i>
3.7.2. <i>Metody wykorzystujące znormalizowane innowacje.....</i>	<i>24</i>
3.7.3. <i>Podjęcie wykorzystujące „surowe” dane pomiarowe i telesygnaly.....</i>	<i>28</i>
3.7.4. <i>Podsumowanie</i>	<i>36</i>
4. TECHNIKI SZTUCZNEJ INTELIGENCJI.....	38
4.1. WPROWADZENIE	38
4.2. SZTUCZNE SIECI NEURONOWE	38
4.2.1. <i>Wprowadzenie</i>	<i>38</i>
4.2.2. <i>Modele komórek neuronowych</i>	<i>39</i>
4.2.3. <i>Typy sieci neuronowych</i>	<i>40</i>
4.2.4. <i>Uczenie sieci neuronowych.....</i>	<i>41</i>
4.2.5. <i>Własności sztucznych sieci neuronowych</i>	<i>41</i>
4.2.6. <i>Zastosowanie sztucznych sieci neuronowych w elektroenergetyce.....</i>	<i>42</i>
4.3. SYSTEMY EKSPERTOWE	42
4.4. LOGIKA ROZMYTA	44
4.5. ALGORYTMY GENETYCZNE	45
4.6. ALGORYTM SYMULOWANEGO WYŻARZANIA	46
4.7. PODSUMOWANIE	47
5. SZTUCZNE SIECI NEURONOWE – SPECYFICZNE PROBLEMY	50
5.1. WPROWADZENIE	50
5.1. ARCHITEKTURA SIECI NEURONOWEJ	52
5.2. FUNKCJA AKTYWACJI.....	53
5.3. INICJACJA WAG.....	53
5.4. ZBIORY UCZĄCE I UCZENIE SIECI NEURONOWYCH	54

6. NOWA METODA WERYFIKACJI TOPOLOGII SYSTEMU ELEKTRO-ENERGETYCZNEGO	58
6.1. CHARAKTERYSTYKA PODEJŚCIA	58
6.2. PODSTAWY TEORETYCZNE	61
6.2.1. <i>Brane pod uwagę związki</i>	61
6.2.2. <i>Definicje wskaźników niezbilansowania dla węzłów</i>	62
6.2.3. <i>Definicje wskaźników niezbilansowania dla gałęzi</i>	62
6.2.4. <i>Analiza wskaźników niezbilansowania dla węzłów w przypadku braku błędów topologii</i>	63
6.2.5. <i>Analiza wskaźników niezbilansowania dla węzła w przypadku nieuwzględnienia w modelu rzeczywistości włączonej gałęzi</i>	64
6.2.6. <i>Analiza wskaźników niezbilansowania dla węzłów w przypadku uwzględnienia w modelu rzeczywistości wyłączonej gałęzi</i>	65
6.2.7. <i>Analiza wskaźników niezbilansowania dla gałęzi w przypadku braku błędów topologii</i>	65
6.2.8. <i>Analiza wskaźników niezbilansowania dla rzeczywistości włączonej gałęzi w przypadku nieuwzględnienia jej w modelu</i>	66
6.2.9. <i>Analiza wskaźników niezbilansowania dla rzeczywistości wyłączonej gałęzi w przypadku uwzględnienia jej w modelu</i>	68
6.2.10. <i>Analiza wskaźników niezbilansowania dla właściwie uwzględnionej w modelu gałęzi incydentnej do węzła, do którego dochodzi gałąź rozpatrzona w rozdz. 6.2.8.</i>	70
6.2.11. <i>Podsumowanie</i>	71
6.3. IDEA NOWEJ METODY	73
6.3.1. <i>Ogólna charakterystyka</i>	73
6.3.2. <i>Blok wstępnej klasyfikacji</i>	74
6.3.3. <i>Lokalny klasyfikator topologii</i>	77
6.3.4. <i>Blok globalnej klasyfikacji</i>	81
6.4. PROBLEMY REALIZACJI KLASYFIKATORÓW LOKALNYCH	82
6.4.1. <i>Tworzenie zbioru uczącego</i>	82
6.4.2. <i>Sposób i przebieg uczenia</i>	84
6.4.3. <i>Wybór architektury sztucznej sieci neuronowej</i>	86
6.4.4. <i>Testowanie działania klasyfikatorów lokalnych</i>	88
6.5. PRZYKŁAD WYKORZYSTANIA METODY	89
6.6. WŁASNOŚCI METODY	93
7. ELEMENTY ORYGINALNE ROZPRAWY	94
8. WNIOSKI I PLANY PRZYSZŁYCH BADAŃ	95
9. LITERATURA	97
DODATEK A. SYSTEM TESTOWY IEEE-14	102
DODATEK B. WYNIKI NA WYJŚCIACH WSTĘPNYCH KLASYFIKATORÓW, GDY NA ICH WEJŚCIA PODAWANE SĄ WSKAŹNIKI NIEZBILANSOWANIA WĘZŁÓW DLA MOCY CZYNNEJ I BIERNEJ	105
DODATEK C. WYNIKI NA WYJŚCIACH WSTĘPNYCH KLASYFIKATORÓW, GDY NA ICH WEJŚCIA PODAWANE SĄ WSKAŹNIKI NIEZBILANSOWANIA GAŁĘZI DLA MOCY CZYNNEJ I BIERNEJ	112
DODATEK D. UCZENIE SZTUCZNYCH SIECI NEURONOWYCH	122

1. Wprowadzenie

Energia elektryczna odgrywa istotną rolę w życiu współczesnych społeczeństw. Dążenie do zapewnienia nieprzerwanej, o odpowiednich parametrach jakościowych dostawy energii elektrycznej wymaga stosowania rozwiązań technicznych umożliwiających nadzorowanie, monitorowanie i sterowanie systemem elektroenergetycznym. Komputerowe systemy EMS zapewniające realizację tych zadań znalazły swoje miejsce we współczesnych centrach dyspozytorskich. Dzięki tym systemom stało się możliwe przetwarzanie dużej ilości danych z systemu elektroenergetycznego w czasie rzeczywistym.

Wśród zadań realizowanych przez systemy komputerowe dyspozycji mocy można wyróżnić dwie podstawowe grupy. Jedna obejmuje zbieranie, sortowanie, gromadzenie oraz kontrolę przekroczenia zadanych wartości przez dane wyodrębnianych wielkości w systemie elektroenergetycznym (SCADA - *Supervisory Control and Data Acquisition*). Druga obejmuje systemową analizę i monitorowanie pracy sieci elektroenergetycznej (realizowanej z wykorzystaniem oprogramowania PAS - *Power Application Software*).

W zakresie wciąż rozwijanego oprogramowania systemów EMS można wyróżnić grupy programów wykorzystywanych do monitorowania, analizy i zwiększania bezpieczeństwa systemu elektroenergetycznego, analiz ekonomicznych oraz prognozy obciążenia, sterowania generacją. Podstawą poprawnego działania tych programów jest znajomość kompletnego, spójnego oraz poprawnego modelu systemu elektroenergetycznego, który powinien możliwie dokładnie odzwierciedlać zachowanie się systemu elektroenergetycznego z punktu widzenia wyznaczonych celów.

W modelu systemu elektroenergetycznego wyróżnić można część statyczną i dynamiczną. Część statyczna zawiera parametry poszczególnych elementów systemu i informacje o ich wzajemnym powiązaniu. Część statyczna jest zmieniana jedynie w przypadku dodania nowego, usunięcia, bądź zamiany już istniejącego elementu systemu.

Dynamiczna część modelu systemu jest tym fragmentem modelu, który ma niezwykle istotne znaczenie dla zapewnienia monitorowania oraz analizy bezpieczeństwa systemu elektroenergetycznego w czasie rzeczywistym. Ta część modelu jest ściśle związana z napływającymi na bieżąco z systemu elektroenergetycznego danymi o stanach łączników, danymi pomiarowymi o przepływach mocy czynnej oraz biernej, poziomach napięć itd.

Część statyczna jest już tworzona fazy wdrażania systemu EMS. Modyfikacje danych zawartych w bazach danych części statycznej modelu są rzadkie i obejmują przypadki rozbudowy

dowy sieci elektroenergetycznej o nowe elementy. Z kolei część dynamiczna modelu podlega ciągłym zmianom. Telepomiarzy, telesygnali są na bieżąco zbierane i wprowadzane do odpowiednich baz danych.

Błędy w części statycznej modelu systemu zdarzają się stosunkowo rzadko. Inna sytuacja jest w odniesieniu do danych związanych z częścią dynamiczną modelu. Te dane muszą być testowane pod względem poprawności w trybie bezpośrednim tak, aby mogły być wykorzystane do tworzenia użytecznego modelu systemu. Budowa poprawnego i spójnego modelu systemu jest jednym z wykonywanych w pierwszej kolejności w czasie rzeczywistym bardzo istotnych zadań systemu komputerowego w dyspozycji mocy. Proces określania modelu systemu w czasie rzeczywistym jest ściśle związany z estymacją stanu. Programy estymacji stanu systemu elektroenergetycznego realizują następujące funkcje:

- analiza topologii,
- analiza obserwowalności,
- statyczna estymacja stanu,
- detekcja i eliminacja błędnych danych,
- kontrola przekroczeń.

Analiza topologii ma za zadanie określenie połączeń między wszystkimi elementami systemu. Danymi wejściowymi dla analizy topologii są dane o połączeniach przechowywane w części statycznej modelu oraz zbierane na bieżąco dane o stanach łączników w sieci elektroenergetycznej. W przypadku, gdy te dane o stanach łączników - zapamiętane w bazach danych systemu komputerowego dyspozycji mocy - są błędne, albo nie uległy dostatecznie szybko zmianie przy zmianie połączeń w rzeczywistej sieci, wtedy topologia systemu elektroenergetycznego jest niewłaściwie określona - mają miejsce błędy topologii.

Topologia systemu elektroenergetycznego stanowi najistotniejszy element modelu systemu. Błędy topologii pociągają za sobą:

- niewłaściwe określenie wektora stanu,
- niewłaściwe wskazanie błędnych danych w procesie weryfikacji danych pomiarowych,
- pozorne przekraczanie ograniczeń,
- błędną bazę do analiz bezpieczeństwa systemu elektroenergetycznego,
- niewiarygodność modelu sieci elektroenergetycznej.

Skumulowany efekt błędów topologii daje w konsekwencji podważenie zaufania do całego pakietu programów PAS. Na całe szczęście błędne dane o stanach łączników, w porównaniu z błędnymi danymi pomiarowymi, pojawiają się stosunkowo rzadko. Jednak

konsekwencje błędów w danych o stanach łączników są o wiele bardziej dotkliwe i na ogół nie do przyjęcia.

Problem błędów topologii był już zauważany w początkowym okresie rozwoju systemów EMS. Jednakże dążenie do znalezienia korzystniejszych sposobów weryfikacji topologii obserwuje się w dalszym ciągu.

Po przedstawieniu celu, tezy oraz zakresu niniejszej pracy w rozdziale 3 omówione zostały spotykane w literaturze metody weryfikacji topologii. Metody te scharakteryzowano, dzieląc je na grupy w zależności od tego, co stanowi podstawę procesu weryfikacji - "surowe" dane pomiarowe, wyniki estymacji statycznej czy też wyniki estymacji dynamicznej. Rozdział 3 zakończono porównaniem własności omawianych metod weryfikacji topologii.

Często w chwili obecnej, przy opracowywaniu nowych metod weryfikacji zwraca się uwagę na wykorzystanie technik sztucznej inteligencji. Rozdział 4 ma na celu scharakteryzowanie najważniejszych osiągnięć w zakresie sztucznej inteligencji, które mogą mieć znaczenie z punktu widzenia analiz dla potrzeb weryfikacji topologii.

Rozdział 5 koncentruje uwagę na specyficznych problemach sztucznych sieci neuronowych, których wykorzystanie do weryfikacji topologii można zaobserwować w wielu współczesnych pracach. Również u podstaw tej pracy było założenie o wykorzystaniu sztucznych sieci neuronowych.

Rozdział 6 poświęcony jest przedstawieniu wyników prac nad nową metodą weryfikacji topologii. W rozdziale tym systematycznie omawiane są: opracowana koncepcja postępowania przy weryfikacji topologii, wykorzystywana wiedza o systemie elektroenergetycznym, wskaźniki zdefiniowane na potrzeby nowej metody, idea nowej metody weryfikacji topologii, rozwiązanie problemów związanych z wykorzystaniem sztucznych sieci neuronowych, przykład obliczeniowy ilustrujący działanie metody i w części końcowej charakterystyka jej właściwości.

W rozdziale 7 podana jest lista oryginalnych osiągnięć w pracy nad weryfikacją topologii systemu elektroenergetycznego, a w rozdziale 8 uwagi końcowe i plany przyszłych badań.

W dodatku A zamieszczono parametry i schemat wykorzystanego systemu testowego IEEE-14, w dodatkach B oraz C - przykładowe wyniki na wyjściach klasyfikatorów wstępnych, gdy na ich wejścia podawane są wskaźniki niezbilansowania dla węzłów i gałęzi, a w dodatku D - wykresy przebiegu błędu uczenia sieci neuronowych klasyfikatorów lokalnych.

2. Cel, teza i zakres rozprawy

Zakres wykrywalności różnych typów błędów topologii jest różny dla różnych metod kontroli poprawności topologii. Szczególnie wąski ten zakres jest dla metod, których głównym celem nie jest weryfikacja topologii. Na ogół nie można jednak wskazać metody, która pozwalałaby wykrywać wszystkie wyróżniane błędy topologii, przy wykorzystaniu nieskomplikowanych obliczeń i zapewnieniu dużej szybkości działania.

Analiza omawianych w literaturze metod pokazuje, że nie wykorzystane zostały wszystkie możliwości, jakie daje zastosowanie sztucznych sieci neuronowych. W pracach dotyczących sztucznych sieci neuronowych wskazuje się na to, że wykorzystanie tych sieci bez uwzględnienia posiadanej wiedzy teoretycznej prowadzi do mało efektywnych rozwiązań [5], [22]. Mimo, że sieci neuronowe wykazują zdolność odnajdywania związków między danymi wejściowymi i wyjściowymi, duża część potencjalnie użytecznej informacji dotyczącej systemu, zawarta w wiedzy teoretycznej, jest bowiem nieuwzględniana. Poza tym ta dodatkowa wiedza teoretyczna o systemie elektroenergetycznym pozwala na ogół zmniejszyć rozmiary sieci neuronowych, co daje lepsze warunki do jej uczenia, jej optymalizacji i w efekcie korzystniejsze właściwości otrzymanego rozwiązania. W ten sposób jest możliwość zredukowania problemu "przekleństwa wielowymiarowości".

Uwzględniając aktualny stan rzeczy, sformułowano tezę rozprawy doktorskiej w następującym brzmieniu:

Istnieje możliwość, a także potrzeba, opracowania nowej, korzystniejszej, aniżeli istniejące, metody weryfikacji topologii systemu elektroenergetycznego, wykorzystującej zbiór dostępnych danych pomiarowych, wiedzę teoretyczną o systemie elektroenergetycznym oraz technikę sztucznych sieci neuronowych.

Zakres rozprawy określają następujące elementy:

- Wykorzystanie „surowych” danych pomiarowych i telesygnatów.

Wykorzystanie wyników estymacji stanu prowadzi do uzależnienia weryfikacji topologii od charakterystyki procesu estymacji. W przypadku wystąpienia błędu topologii, nieobserwowalności części systemu, obecności błędnych danych, przeprowadzenie estymacji stanu może okazać się utrudnione albo wręcz niemożliwe, a gdy już jest możliwość jej

przeprowadzenia, jej wyniki mogą być mało przydatne. Rzutuje to na skuteczność weryfikacji topologii. Poza tym zwiększa się złożoność obliczeniowa. Podane okoliczności uzasadniają dążenie do wykorzystania „surowych” danych pomiarowych.

- Wykorzystanie szerszej, aniżeli dotychczas, wiedzy wynikającej ze związków opisujących system elektroenergetyczny.

Na ogół wykorzystanie szerszej wiedzy teoretycznej powoduje zwiększenie efektywności działania. Stwierdzono to także w zakresie prac nad wykrywaniem błędów topologii.

- Zastosowanie sieci neuronowych.

Analiza cech, jakie posiadają sztuczne sieci neuronowe, pozwoliła stwierdzić ich przydatność do weryfikacji topologii. Literatura z zakresu problemu weryfikacji topologii potwierdziła te spostrzeżenia.

3. Topologia systemu elektroenergetycznego

3.1. Wprowadzenie

Topologia (gr. *topos* – miejsce) lub konfiguracja systemu elektroenergetycznego to układ połączeń poszczególnymi jego elementami. Graficzną reprezentację topologii stanowi graf. Do opisu topologii stosuje się macierz incydencji [23].


Mówiąc o topologii systemu elektroenergetycznego, będą dalej wykorzystywane pojęcia węzła (wierzchołka) i gałęzi. Przez węzeł będzie rozumiany punkt, do którego dochodzą (od którego odchodzą) gałęzie. Gałąź stanowić może linia elektroenergetyczna, odbiór, generator, itd.

3.2. Określanie topologii systemu elektroenergetycznego

Do automatycznego określania topologii systemu elektroenergetycznego stosuje się specjalne programy nazywane procesorami topologii (ang. *topology processor*). Danymi wejściowymi dla tych programów są telesygnaly, informujące o stanach łączników w sieci elektroenergetycznej oraz informacje dotyczące połączeń w sieci przechowywane w bazie danych.

Analiza topologii systemu elektroenergetycznego polega na określeniu macierzy incydencji na podstawie danych o stanach łączników uzyskanych z systemu. W przypadku wystąpienia zmian stanów wyłączników uruchamiany jest program procesora topologii i określany jest nowy układ połączeń.

Dla automatycznego określania topologii opracowano szereg metod wykorzystujących strategię przeszukiwania grafu sieci [38] [56]. Proponowane jest także zastosowanie systemów ekspertowych [58].



Rys. 3.1. Schemat blokowy systemu automatycznego określania topologii

3.3. Błędy topologii systemu elektroenergetycznego

Błędem topologii systemu elektroenergetycznego jest nieprawidłowe uwzględnienie w modelu topologii systemu jego elementów składowych (linii, generatorów, odbiorów, itd.).

Wyróżnia się następujące błędy topologii:

1. Gałąź jest obustronnie włączona w modelu, podczas gdy w rzeczywistości jest jednostronnie włączona.
2. Gałąź jest obustronnie włączona w modelu, podczas gdy w rzeczywistości jest obustronnie wyłączona.
3. Gałąź jest jednostronnie włączona w modelu, podczas gdy w rzeczywistości jest on obustronnie włączona.
4. Przyjęcie wyłączenia gałęzi na innym końcu aniżeli w rzeczywistości.
5. Gałąź jest jednostronnie włączona w modelu, podczas gdy w rzeczywistości jest obustronnie wyłączona.
6. Gałąź jest obustronnie wyłączona w modelu, podczas gdy w rzeczywistości jest obustronnie włączona.
7. Element jest obustronnie wyłączony w modelu, podczas gdy w rzeczywistości jest on jednostronnie włączony.
8. Uwzględnienie w modelu innej niż w rzeczywistości liczby węzłów.
9. Nieuwzględnienie w modelu gałęzi reprezentującej generator, odbiór, bocznic lub inny element włączony poprzecznie.

Oprócz błędów jednokrotnych mogą występować wielokrotne błędy topologii. Błędy wielokrotne mają miejsce wtedy, gdy więcej niż jeden z element składowy systemu elektroenergetycznego jest niewłaściwie uwzględniony w modelu topologii.

3.4. Przyczyny powstawania błędów topologii

Do przyczyn powstawania błędów topologii zaliczyć można:

- niewłaściwe działanie układów określania stanów wyłączników,
- przekłamania lub przerwy przesyłu telesygnatów liniami transmisji danych,
- brak lub zakłócenia w synchronizacji zbierania telesygnatów z różnych miejsc systemu elektroenergetycznego,
- zniekształcenia w danych i stanach wyłączników w wyniku niewłaściwej pracy systemu komputerowego.

3.5. Pojęcie weryfikacji topologii systemu elektroenergetycznego

Weryfikacja topologii systemu elektroenergetycznego jest procesem, w wyniku którego podejmowana jest decyzja o wystąpieniu błędu topologii w ogóle lub także podejmowane są decyzje o istnieniu błędów topologii odnoszących się do konkretnych elementów systemu elektroenergetycznego. Weryfikacja topologii systemu elektroenergetycznego jest więc procesem decyzyjnym. Ma on na celu sprawdzenie zgodności informacji o topologii odwzorowanej w modelu systemu elektroenergetycznego ze stanem rzeczywistym. Wykrywanie błędów topologii w ogóle nazywa się detekcją błędów topologii. Identyfikacja błędów topologii oznacza natomiast wykrywanie błędów topologii odnoszących się do konkretnych elementów systemu elektroenergetycznego.

Problemowi weryfikacji topologii, mimo że został on zauważony w latach siedemdziesiątych, początkowo nie poświęcano zbyt wiele uwagi. Pierwsze prace na temat weryfikacji topologii pojawiają się w połowie lat siedemdziesiątych. Większe zainteresowanie zauważyć można na początku lat osiemdziesiątych. Dalszy wzrost zainteresowania obserwuje się od połowy lat dziewięćdziesiątych, co należy przypisać przede wszystkim intensywnemu rozwojowi nowych metod wykorzystujących inteligentne techniki obliczeniowe.

3.6. Klasyfikacja podejść do weryfikacji topologii systemu elektroenergetycznego

Wśród istniejących podejść do problemu weryfikacji topologii systemu elektroenergetycznego, przyjmując jako kryterium rodzaj wykorzystywanej informacji wyróżnić można następujące podejścia do problemu weryfikacji topologii systemu elektroenergetycznego [31]:

- podejście wykorzystujące wyniki estymacji stanu,
- podejście wykorzystujące znormalizowane innowacje,
- podejście wykorzystujące „surowe” dane pomiarowe i telesygnały.

3.7. Przegląd metod weryfikacji topologii systemu elektroenergetycznego

3.7.1. Metody wykorzystujące wyniki estymacji stanu

Idea estymacji stanu metodą najmniejszych kwadratów

W klasycznym podejściu do statycznej estymacji stanu zbiór danych pomiarowych przepływów mocy czynnej, biernej, węzłowych mocy czynnych i biernych, modułów napięcia jest powiązany z wektorem zmiennych stanu (modułami napięć i kątami fazowymi), poprzez zbiór równań nieliniowych [27], [42]:

$$\mathbf{z} = h(\mathbf{x}) + \mathbf{e}, \quad (3.1)$$

gdzie:

$\mathbf{z}$ – wektor danych pomiarowych;

$h(\mathbf{x})$ – nieliniowa funkcja wektorowa opisująca zależność wielkości podlegających pomiarom od zmiennych stanu;

$\mathbf{x}$ – wektor stanu;

$\mathbf{e}$ – wektor błędów.

Estymacja wektora stanu $\hat{\mathbf{x}}$ polega na znalezieniu wektora $\mathbf{x}$ minimalizującego skalarną funkcję celu $J(\mathbf{x})$. Często wykorzystywana jest funkcja celu postaci

$$J(\mathbf{x}) = [\mathbf{z} - h(\mathbf{x})]^T R^{-1} [\mathbf{z} - h(\mathbf{x})], \quad (3.2)$$

gdzie:

R – diagonalna macierz wagowa.

W przypadku stosowania wyżej wymienionej funkcji celu rozwiązanie $\hat{\mathbf{x}}$ minimalizujące funkcję celu spełnia zależność:

$$\frac{\partial J(\mathbf{x})}{\partial \mathbf{x}} \Big|_{\mathbf{x}=\hat{\mathbf{x}}} = -2H^T(\mathbf{x})R^{-1}[\mathbf{z} - h(\mathbf{x})] = 0, \quad (3.3)$$

gdzie:

H – macierz jacobianowa.

Taka metoda estymacji nosi nazwę metody ważonych najmniejszych kwadratów (*Weighted Least Squares* – WLS).

Metody weryfikacji topologii systemu elektroenergetycznego wykorzystują wyniki estymacji stanu. Analizowany jest wektor residuów pomiarowych $\mathbf{r}$ zdefiniowany jako:

$$\mathbf{r} = \mathbf{z} - h(\mathbf{x}), \quad (3.4)$$

Wektory residuów $\mathbf{r}$ i błędów $\mathbf{e}$ powiązane są zależnością:

$$\mathbf{r} = W\mathbf{e}, \quad (3.5)$$

gdzie:

W – macierz wrażliwości residuów.

Wektor residuów przedstawia się także w postaci znormalizowanej:

$$\left| r_i^N \right| = \frac{|r_i|}{\sigma_i}, \quad (3.6)$$

gdzie:

σ_i – standardowe odchylenie i -tego elementu wektora residuów (r_i).

Metody wykorzystujące analizę znormalizowanych residuów

Jedną z pierwszych metod wykorzystujących analizę residuów przedstawiono w [30]. Po przeprowadzeniu estymacji stanu i procesu eliminacji błędnych danych, tj. obarczonych dużymi błędami, przeprowadzane jest ponowne testowanie wyeliminowanych danych pomiarowych mocy węzłowych potraktowanych jako błędne, przy czym rozpatruje się:

- wyłączenie gałęzi dla której dane pomiarowe nie są w ogóle dostępne, lub dla której dane pomiarowe zostały wyeliminowane,
- włączenie gałęzi nie uwzględnionej w modelu,
- włączenie gałęzi wyłączonej na jednym końcu.

Przeprowadzona analiza wskazuje, że błędy topologii nie wpływają na zmienne wektora stanu, jeśli rozpatrywana gałąź jest nieopomiarowana lub dane pomiarowe z nią skojarzone zostały wyeliminowane w procesie identyfikacji błędnych danych. Wynika to stąd, że model rozpatrywanej gałęzi jest pominięty w równaniach estymacji.

Rezultatem błędnego uwzględnienia gałęzi jest niepoprawna wartość estymaty przepływów mocy węzłowej w węzłach na końcach gałęzi. W przypadku występowania odpowiednio dużej redundancji pomiarowej, poziomy napięć i kąty fazowe oraz dane pomiarowe przepływów mocy w gałęzi ulegają znacznie mniejszemu wpływowi błędów topologii niż dane pomiarowe mocy węzłowych. W tej sytuacji dane pomiarowe mocy węzłowych w węzłach końcowych rozpatrywanej gałęzi ze znacznie większym prawdopodobieństwem będą zidentyfikowane jako błędne dane i eliminowane ze zbioru rozpatrywanych danych pomiarowych.

Metoda pozwala na detekcję błędów uwzględnienia i nieuwzględnienia gałęzi, wyłączenia gałęzi na jednym końcu w modelu, ale nie w rzeczywistości, wyłączenia gałęzi na jednym końcu w rzeczywistości, ale nie w modelu.

Metoda pozwala rozważyć różne kombinacje błędów topologii w otoczeniu gałęzi, która nie jest właściwie uwzględniona w modelu systemu. Jest prosta i szybka, wymaga jednak przeprowadzenia estymacji stanu. Przy testowaniu metody uwzględniono jedynie dane pomiarowe dla mocy czynnej. Do testów wykorzystano system testowy IEEE-30.

Metoda zaproponowana w [55] do detekcji błędów topologii wykorzystuje test znormalizowanych residuów $\mathbf{r}^N$. W przypadku, gdy nie występują grube błędy obarczające dane pomiarowe i błędy topologii, wartość oczekiwana wektora residuów wynosi :

$$E(\mathbf{r}) = 0. \quad (3.7)$$

W przypadku wystąpienia błędów topologii wartość oczekiwana może być różna od zera.

Hipoteza o braku błędnych danych i błędów topologii jest przyjmowana, gdy:

$$\max_i |r_i^N| < \gamma, \quad (3.8)$$

gdzie:

i – numer elementu wektora znormalizowanych residuów,

γ – próg przyjęcia hipotezy.

W przypadku stwierdzenia wystąpienia błędu topologii, kolejnym etapem jest określenie miejsca jego wystąpienia. W tym celu wyznaczana jest macierz wrażliwości S , której element S_{ij} w przybliżeniu określony jest przez zależność:

$$S_{ij} = \frac{\Delta r_i^N}{\Delta f_j}, \quad (3.9)$$

gdzie:

Δr_i^N – zmiana wektora znormalizowanych residuów,

Δf_j – zmiana wartości przepływu w gałęzi j .

W [55] wykazano, że wektor $E(\mathbf{r}^N)$ jest liniową kombinacją kolumn macierzy S , które odpowiadają wyłączonym gałęziom. Nie istnieje jednak tylko jeden zbiór kolumn tworzących taką liniową kombinację. Poza tym znalezienie liniowej kombinacji kolumn dającej w efekcie $E(\mathbf{r}^N)$ jest problemem bardzo złożonym numerycznie.

W trakcie testów metody rozpatrzono błędy topologii polegające na uwzględnieniu oraz nieuwzględnieniu gałęzi wzdłużnych, nieuwzględnieniu elementów bocznikowych i podziału węzła. Metoda obejmuje także możliwość badania wystąpienia wielokrotnych błędów topologii.

Autorzy formułują warunki określające sytuacje, w których nie jest możliwe wykrycie rozpatrywanych błędów topologii. Pewnych rodzajów błędów topologii nie można wykryć w przypadku nieobserwowalności części systemu, bądź w przypadku braku odpowiednio dużej liczby danych pomiarowych.

Metodę testowano wykorzystując systemu testowy IEEE-30. W trakcie testów rozpatrywano wektor znormalizowanych residuów dla mocy czynnej.

Metodę opartą na geometrycznej interpretacji residuów pomiarowych, spowodowanych przez wystąpienie błędów topologii podano w [10]. Zależność między residuami pomiarowymi a błędami przepływów w gałęziach opisuje zależność:

$$\mathbf{r} = W M \Delta f(\mathbf{x}), \quad (3.10)$$

gdzie:

M – macierz incydencji pomiarów i gałęzi,

$\Delta f(\mathbf{x})$ – błąd przepływów gałęziowych spowodowany błędem topologii.

Z zależności (3.10) wynika, że istnieje zależność liniowa między wektorem residuów i kolumnami macierzy WM , odnoszących się do gałęzi niepoprawnie modelowanych. Zależność liniowa jest sprawdzana przez wyznaczenie wartości:

$$\cos \theta_T = \left(\frac{\mathbf{p} \mathbf{p}^T}{\mathbf{r} \mathbf{r}^T} \right)^{\frac{1}{2}}, \quad (3.11)$$

gdzie:

θ_T – kąt między wektorami $\mathbf{p}$ i $\mathbf{r}$,

$$\mathbf{p} = W M_S (M_S^T W M_S)^{-1} M_S^T W \mathbf{r},$$

M_S – podmacierz macierzy M , której kolumny opisują gałęzie ze zbioru S , gdzie S jest zbiorem gałęzi podejrzanych o to, że są niewłaściwie uwzględnione w modelu.

Następnie testowana jest hipoteza, czy zbiór S zawiera wszystkie gałęzie, które są niewłaściwie uwzględnione w modelu. Hipoteza ta jest przyjmowana, gdy $\cos \theta_T = 1$.

Za pomocą tej metody możliwe jest wykrywanie pojedynczych i wielokrotnych błędów topologii. Nie jest jednak łatwe właściwe ustalenie zbioru S . Na podstawie analizy zależności algebraicznych podane zostały w [10] warunki detekcji i identyfikacji błędów topologii. Nie został jednakże poruszony wpływ błędnych danych pomiarowych na wyniki weryfikacji topologii. Testowanie działania metody przeprowadzono dla systemu testowego IEEE-14.

Kolejną metodą wykorzystującą wyniki estymacji stanu metodą ważonych najmniejszych kwadratów przedstawioną w [24], [25] wykorzystuje fakt, że przy zaistnieniu błędu topologii w wynikach dostarczanych przez estymację stanu zachodzą niespójności w otoczeniu tego błędu. Procedura eliminowania błędnych danych usuwa w pierwszej kolejności błędy powstałe w sąsiedztwie nieprawidłowo modelowanych elementów systemu, aż do uzyskania sytuacji w której lokalna redundancja danych pomiarowych w miejscu wystąpienia błędu zostaje usunięta. Nagromadzenie przypuszczalnie błędnych danych wskazuje na możliwość wystąpienia błędu topologii. Dysponując zbiorem wyeliminowanych danych, w prosty sposób możliwe jest stworzenie zbioru węzłów i gałęzi, które mogą być podejrzewane o to, że są niewłaściwie uwzględnione w modelu. W dalszej analizie rozpatruje się stacje elektroenergetyczne i związane z nimi gałęzie, dla których są spełnione warunki:

- występuje dana pomiarowa mocy węzłowej dla węzła, który stanowi stacja lub któraś ze stacji w bezpośrednim sąsiedztwie,
- występuje dana pomiarowa dla przepływu mocy w gałęzi dochodzącej do stacji, które zostały potraktowane jako przypuszczalnie nieprawidłowo uwzględnione.

Jeśli stacja i spełnia powyższe warunki, tworzona jest podsieć M złożona z tej stacji, stacji sąsiednich oraz gałęzi połączonych z daną stacją elektroenergetyczną. Dla każdej stacji, w której wystąpić może błąd topologii, przeprowadzane jest testowanie stanu połączeń poprzez estymację metodą najmniejszych ważonych kwadratów. Dla stacji i , podsieci M oraz układu połączeń ξ , wyznaczana jest wartość funkcji celu $J_{M, i\xi}$:

$$J_{M, i\xi} = \sum_{i=1}^m r_{i,w}^2, \quad (3.12)$$

gdzie:

r_w – wektor ważonych residuów,

m – liczba mierzonych wartości.

Jeśli dla określonej stacji i oraz układu połączeń ξ ogólna funkcja celu:

$$J_{i\xi} = J_{Si} + J_{M,i\xi}, \quad (3.13)$$

gdzie:

J_{Si} – funkcja celu dla otoczenia stacji i .

ma najmniejszą wartość, błąd topologii występuje w stacji i , zaś układ połączeń ξ jest najbardziej prawdopodobny.

Metodę tą można wykorzystać do wykrywania błędów topologii w stacjach elektroenergetycznych ze złożonymi układami połączeń szyn zbiorczych. Możliwe jest wykrywanie wielokrotnych błędów topologii. Estymacja stanu podsieci jest problemem nieliniowym. Możliwa jest jednak linearyzacja równań i tym samym uniknięcie rozwiązywania metodami iteracyjnymi. Liczba możliwych układów połączeń rośnie bardzo szybko z liczbą węzłów i gałęzi, jednak możliwe jest jej ograniczenie przez uwzględnienie jedynie układów połączeń uzasadnionych z punktu widzenia poprawnej pracy sieci. Metoda nie wymaga, większej niż w przypadku detekcji i identyfikacji błędnych danych, redundancji pomiarowej. Testowanie metody przeprowadzono dla systemu złożonego z 24 stacji elektroenergetycznych.

Metoda zaproponowana w [11] używa wskaźników opisujących korelację między wielkościami estymowanymi wskazującymi na istnienie błędnych danych i błędów topologii. Algorytm obejmuje następujące kroki:

- Przeprowadzenie estymacji stanu i identyfikacja błędnych danych,
- Stworzenie zbioru danych uznanych za błędne (STM),
- Stworzenie listy elementów związanych z błędnymi danymi ze zbioru STM ,
- Określenie zbioru SST_{i-j} , tj. zbioru danych wrażliwych na błędne uwzględnienie gałęzi $i-j$. Zbiór SST_{i-j} zawiera dane związane z ρ_{i-j} elementami o największych wartościach w kolumnie S_{i-j} macierzy wrażliwości S ; ρ_{i-j} jest równe liczbie danych dotyczących gałęzi $i-j$. Macierz S jest macierzą wrażliwości znormalizowanych residuów w odniesieniu do przepływów mocy przez elementy sieci.

Zależność między znormalizowanymi residuami a przepływami mocy przez elementy sieci ma postać:

$$\mathbf{r}^N = S\mathbf{f}(\mathbf{x}), \quad (3.14)$$

gdzie:

$\mathbf{r}^N$ – wektor znormalizowanych residuów,

S – macierz wrażliwości,

$\mathbf{f}(\mathbf{x})$ – wektor przepływów mocy przez elementy sieci.

Wyznaczane są wskaźniki e_{i-j} :

$$e_{i-j} = \frac{|STM \cap SST_{i-j}|}{\rho_{i-j}}, \quad (3.15)$$

gdzie:

licznik wyrażenia oznacza liczbę elementów części wspólnej zbiorów.

Wartości wskaźników e_{i-j} i inne dodatkowe informacje wykorzystywane w celu podjęcia decyzji, o przypisaniu niespójności w zbiorze danych któremuś z elementów, które mogą być nieprawidłowo uwzględnione w modelu systemu. W przypadku pozytywnej decyzji zmieniany jest stan gałęzi i proces zaczyna się od nowa. W przypadku negatywnej decyzji podejmowana jest decyzja o wystąpieniu błędnych danych.

W pracy [11] określone zostały warunki braku możliwości wykrycia błędów topologii. Są one następujące:

- brak jest danych pomiarowych związanych z daną gałęzią,
- wszystkie dane pomiarowe związane z daną gałęzią są krytyczne lub stają się krytyczne w związku z wystąpieniem błędu topologii,
- dwie gałęzie tworzą parę krytycznych gałęzi.

Testowanie metody przeprowadzono dla systemów testowych IEEE-14 i IEEE-30 oraz przykładowego systemu liczącego 48 węzłów. Metoda pozwala na wykrywanie pojedynczych, jak i wielokrotnych błędów topologii uwzględnienia i nieuwzględnienia gałęzi oraz błędów podziału węzła (uwzględnienia innej niż w rzeczywistości liczby węzłów).

Ideę modelowania wyłączników jako gałęzi przez uwzględnienie jako zmiennych przepływających przez nie mocy zastosowano w metodzie przedstawionej w [2]. Zastosowano dwuetapową procedurę, wykorzystującą estymator ważonej najmniejszej wartości bezwzględnej (*Weighted Least Absolute Value* – WLAV). W pierwszym etapie przeprowadzana jest estymacja stanu, po czym identyfikowane są przekraczające wartość progową, znormalizowane residua i związane z nimi węzły i gałęzie.

Rozwijając zależność (3.1) w szereg Taylor’a, wokół punktu $\mathbf{x}_0$, można zapisać:

$$\Delta \mathbf{z} = H \Delta \mathbf{x} + \mathbf{e}, \quad (3.16)$$

gdzie: $\Delta \mathbf{z} = \mathbf{z} - h(\mathbf{x}_0)$, $\Delta \mathbf{x} = \mathbf{x} - \mathbf{x}_0$.

Estymacja WLAV znajduje estymatę wektora stanu $\hat{\mathbf{x}}$ poprzez minimalizację funkcji celu w postaci:

$$J(\mathbf{x}) = \sum_{i=1}^m w_i |r_i|, \quad (3.17)$$

gdzie:

$$r_i = z_i - h_i(\mathbf{x}),$$

w_i – współczynnik wagowy i -tego residuum,

m – liczba elementów wektora stanu.

Autorzy zastosowali modyfikację zależności (3.1) w następującej postaci:

$$\Delta \mathbf{z} = H \Delta \mathbf{x} + M \Delta \mathbf{f} + \mathbf{e}, \quad (3.18)$$

gdzie:

M – macierz incydencji pomiarów i wyłączników ($M_{ij} = 1$, gdy kierunek przepływu jest skierowany do wyłącznika j umieszczonego na końcu gałęzi, $M_{ij} = -1$, gdy kierunek przepływu jest skierowany od wyłącznika j umieszczonego na końcu gałęzi),

$\Delta \mathbf{f}$ – wektor przepływów mocy przez wyłączniki (wektor ma zerowe elementy, gdy wszystkie wyłączniki są otwarte).

W drugim etapie wektor stanu rozszerzany jest o nowe zmienne pochodzące ze szczegółowej reprezentacji stacji elektroenergetycznych i gałęzi zidentyfikowanych w pierwszym etapie. Powtórnie przeprowadzana jest estymacja stanu, uwzględniająca rozszerzony wektor stanu. Wartości $\Delta \hat{\mathbf{f}}$ są wykorzystywane przy wnioskowaniu statystycznym do identyfikacji wyłączników, których stan jest nieprawidłowo uwzględniony. Gdy są one znacznie większe niż przyjęty próg, wyłącznik uznawany jest za zamknięty.

Metoda ta jest bardziej efektywna w wykrywaniu błędów topologii niż metody wykorzystujące estymację ważonych najmniejszych kwadratów, jednakże jej działanie jest w dużym stopniu uzależnione od możliwości wykrywania błędnych danych w pierwszym etapie. Problemy występują szczególnie przy obecności wielu błędnych danych.

Do testowania wykorzystano system testowy IEEE-30.

Podobną metodą, wykorzystującą estymację metodą ważonych najmniejszych kwadratów przedstawiono w [35].

Metoda przedstawiona w [15] proponuje wprowadzenie do wektora stanu pojedynczej zmiennej binarnej k opisującej stan wyłącznika. Wprowadzone zostało ograniczenie równościowe:

$$k(1 - k) = 0, \quad (3.19)$$

aby uniknąć przybrania przez estymatę zmiennej wartości różnych od 0 lub od 1. Modyfikacja może być zastosowana w każdej metodzie estymacyjnej, a zwłaszcza w tych, gdzie uwzględniane są ograniczenia równościowe. Obliczenia testowe przeprowadzone zostały dla systemu testowego IEEE-14.

Wykorzystanie estymacji stanu metodą najmniejszej mediany kwadratów (*Least Median of Squares* – LMS), zaproponowano w [39]. Mediana w pewnych przypadkach jest bardziej reprezentatywną miarą opisu populacji niż średnia, nawet przy obecności odstających danych. W metodzie tej błędy topologii są wykrywane na podstawie różnic między wartościami danych pomiarowych a ich estymatami, tj.:

- w przypadku, gdy dana pomiarowa przepływu ma wartość zerową, zaś estymata wartość znacznie różniącą się od zera,
- gdy estymata wartości przepływu jednego końca gałęzi ma wartość zerową, zaś z drugiego końca różną od zera.

Metoda estymacji LMS zapewnia na ogół lepszą zbieżność w porównaniu do metody estymacyjnej ważonych najmniejszych kwadratów (WLS), nawet w przypadku obecności błędnych danych. Testowanie metody przeprowadzono dla systemu testowego IEEE-14.

W pracy [9] przedstawiono rozszerzenie metody analizy znormalizowanych residuów, jaką jest metoda z zastosowaniem znormalizowanych mnożników Lagrange’a. Wyłącznik jest traktowany jako specyficzna gałąź, z nałożonymi ograniczeniami operacyjnymi, tj. gdy wyłącznik „umieszczony w gałęzi między węzłami i oraz j ”, jest zamknięty, to poziomy napięcie i kąty fazowe na końcach gałęzi są sobie równe. W przypadku otwarcia wyłącznika przepływy mocy w gałęzi są zerowe. Uwzględnione zostały także ograniczenia strukturalne, wynikające z własności fizycznych.

Wykorzystując estymację metodą ważonych najmniejszych kwadratów WLS z ograniczeniami, znajduje się estymatę wektora stanu $\hat{\mathbf{x}}$ przez minimalizację funkcji celu:

$$J(\hat{\mathbf{x}}) = \frac{1}{2} \sum_{i=1}^m R_{ii}^{-1} (z_i - h_i(\hat{\mathbf{x}}))^2, \quad (3.20)$$

gdzie:

R_{ii}^{-1} – wagi błędów pomiarowych,

przy założeniach:

$$h^T(\mathbf{x}) = [h_m^T(\mathbf{x}) \ h_s^T(\mathbf{x}) \ h_o^T(\mathbf{x})], \quad (3.21)$$

$$h_s(\mathbf{x}) = 0, \quad h_o(\mathbf{x}) = 0, \quad (3.22)$$

gdzie:

$h_m(\mathbf{x})$, $h_s(\mathbf{x})$, $h_o(\mathbf{x})$ – wektory funkcji nieliniowych opisujących odpowiednio: zależności zmiennych mierzonych i zmiennych stanu, ograniczenia strukturalne, ograniczenia operacyjne.

Wykorzystując rozwinięcie w szereg Taylor’a wokół punktu $\mathbf{x}_0$:

$$h(\mathbf{x}) \approx h(\mathbf{x}_0) + H \Delta \mathbf{x}_0, \quad (3.23)$$

gdzie:

H – jacobian wektora $h(\mathbf{x})$.

Estymata stanu jest obliczana iteracyjnie na podstawie zależności dla k -tej iteracji obowiązuje zależność:

$$\begin{bmatrix} R & H \\ H^T & 0 \end{bmatrix} \begin{bmatrix} \lambda \\ \Delta \hat{\mathbf{x}} \end{bmatrix} = \begin{bmatrix} \mathbf{r}^{(k)} \\ 0 \end{bmatrix}, \quad (3.24)$$

$$R = \begin{bmatrix} R_m & 0 & 0 \\ 0 & 0 & 0 \\ 0 & 0 & 0 \end{bmatrix}, \quad H = \begin{bmatrix} \partial h_m(\mathbf{x})/\partial \mathbf{x} \\ \partial h_s(\mathbf{x})/\partial \mathbf{x} \\ \partial h_o(\mathbf{x})/\partial \mathbf{x} \end{bmatrix}, \quad \boldsymbol{\lambda} = \begin{bmatrix} \lambda_m \\ \lambda_s \\ \lambda_o \end{bmatrix}, \quad \mathbf{r}^{(k)} = \begin{bmatrix} z_m - h_m(\hat{\mathbf{x}}^{(k)}) \\ -h_s(\hat{\mathbf{x}}^{(k)}) \\ -h_o(\hat{\mathbf{x}}^{(k)}) \end{bmatrix}, \quad (3.25)$$

gdzie:

λ – wektor mnożników Lagrange’a,

R_m – przekątna macierzy współczynników wagowych błędów,

R – macierz kowariancji pomiarów,

$\Delta \mathbf{x} = \hat{\mathbf{x}}^{(k+1)} - \hat{\mathbf{x}}^{(k)}$, $\mathbf{r}^{(k)}$ – wektor residuów.

Autorzy wykazali, że w przypadku zbieżności, spełnione są zależności:

$$R\boldsymbol{\lambda} = \mathbf{r}, \quad H^T \boldsymbol{\lambda} = 0. \quad (3.26)$$

Wektor mnożników Lagrange’a jest wektorem losowym z zerową wartością średnią i macierzą kowariancji:

$$V = E\{\boldsymbol{\lambda} \boldsymbol{\lambda}^T\}. \quad (3.27)$$

Normalizacja wektora mnożników Lagrange’a:

$$\lambda_i^N = \frac{\lambda_i}{\sqrt{V_{ii}}} \quad (3.28)$$

i porównanie ich z określoną wartością progową, pozwala na wskazanie gałęzi, które zostały nieprawidłowo uwzględnione w modelu.

W metodzie tej oprócz wektora stanu rozpatrywane są dodatkowe zmienne, co powoduje większą złożoność obliczeniową niż w przypadku innych metod opartych o estymację stanu. Wymaga też większego nadmiaru danych.

Metoda przedstawiona w [34], [49] wykorzystuje estymator M-Hubera, którego własnością jest to, że w przypadku występowania małych residuów (mniejszych od ustalonej wartości progowej) działa jak estymator najmniejszych kwadratów, zaś dla dużej wartości re-

siduów, działa jak estymator najmniejszej wartości bezwzględnej. Estymacja polega na minimalizacji funkcji celu:

$$J(\mathbf{x}) = \sum_{i=1}^m \rho(r_i^N), \quad (3.29)$$

gdzie:

ρ – estymator M-Hubera.

Postać estymatora M-Hubera:

$$\rho(r_i^N) = \begin{cases} \frac{1}{2} (r_i^N)^2 & \text{dla } |r_i^N| \leq \lambda \\ \lambda |r_i^N| - \frac{c^2}{2} & \text{dla } |r_i^N| > \lambda \end{cases}, \quad (3.30)$$

gdzie:

λ – wartość odcięcia,

r_i^N – i -ty element wektora znormalizowanych residuów,

c – wartość stała.

Estymacja jest przeprowadzana dla dwóch zdekomponowanych modeli dla mocy czynnych i biernych wynikających ze sposobu modelowania stacji elektroenergetycznej, tj. na poziomie węzła uogólnionego i szczegółowego. Zmienne stanu stanowią przepływy mocy czynnej i biernej na jednym z końców każdej gałęzi. Stany gałęzi są określane na podstawie testowania statystycznego estymat przepływów mocy.

Proponowana metoda jest metodą przedestymacyjną. Wykorzystuje przybliżony model systemu elektroenergetycznego. Umożliwia detekcję i identyfikację różnych błędów uwzględnienia w modelu gałęzi wyłączonej, nieuwzględnienia w modelu gałęzi załączonej a także podział węzła. Metoda pozwala na rozróżnienie błędów topologii od błędnych danych. Dzięki własnościom estymatora M-Hubera wykazuje dobrą zbieżność. Testowanie metody przeprowadzono z wykorzystaniem systemu testowego IEEE-118.

W zaproponowanej w [3] metodzie dane pomiarowe, stany łączników i parametry gałęzi stanowią jeden zbiór. Residua wyznacza się na podstawie zmodyfikowanego równania w postaci:

$$r_i = z_i - h_i(\mathbf{x}, \mathbf{s}, \mathbf{y}), \quad (3.31)$$

gdzie:

$\mathbf{x}$ – wektor napięć,

$\mathbf{s}$ – wektor przepływów mocy przez wyłączniki,

y – wektor przepływów mocy przez impedancje sieci o nieokreślonych wartościach.

Uwzględnienie łączników w estymacji stanu pozwala na zwiększenie skuteczności wykrywania błędów w określaniu ich stanów. Modelując łączniki zakłada się, że:

- przepływy mocy czynnej i biernej przez łącznik są zmiennymi stanu,
- w przypadku otwarcia łącznika występują zerowe przepływy, gdy zaś łącznik jest załączony, nie ma na nim spadku napięcia.

Metoda przewiduje wielokrotne wykonywanie obliczeń, które mają na celu znalezienie estymaty stanu, sprawdzanie obecności błędnych danych oraz błędów topologii. Cechuje ją wieloetapowość i złożoność. Do poprawnego działania potrzebuje wyników estymacji stanu. Mimo, że uwzględnienie w równaniach estymacji także zmiennych skojarzonych z wyłącznikami poprawia możliwość wykrycia błędów topologii, zwiększa się nakład potrzebnych obliczeń.

Zastosowanie zredukowanego modelu stacji elektroenergetycznych w stosunku do metody [3] zaproponowano w [16]. Zmniejszenie liczby zmiennych uzyskano dzięki zastosowaniu trzech typów ograniczeń:

- liniowych ograniczeń dla stanów wyłączników,
- nieliniowych ograniczeń dotyczących zależności między przepływami mocy a kątami fazowymi,
- liniowych ograniczeń wynikające z praw Kirchhoffa

Weryfikację topologii przeprowadza się w oparciu o analizę residuów pomiarowych oraz mnożników Lagrange’a.

Testowanie działania metody przeprowadzono dla systemu testowego IEEE-14. Wyniki wskazują, że mimo istotnego uproszczenia równań estymacji w porównaniu do metod modelujących zmienne stanu i ograniczenia dla każdego z wyłączników z [3] (redukcja rozmiaru modelu ponad 50%), nie stwierdzono gorszych wyników w zakresie wykrywania błędnych danych i błędów topologii.

Własności metod wykorzystujących wyniki estymacji stanu

Większość z metod weryfikacji topologii wykorzystujących wyniki estymacji stanu nie dostarcza poprawnych wyników w przypadku występowania dużej liczby błędnych danych.

Istnieją problemy z rozróżnieniem między błędnymi danymi a błędami topologii. Metody analizy wykrywające błędne dane zwykle modyfikują, a nawet usuwają, także poprawne

dane pomiarowe, które są powiązane z wielkościami dla których występują błędne dane. Często tracona jest lokalna redundancja pomiarowa. W efekcie nie ma podstaw do wykrycia błędów topologii.

W przypadku wystąpienia grubych błędów obarczających dane pomiarowe lub błędów topologii po przeprowadzeniu estymacji pojawiają się znormalizowane residua przekraczające ustalony poziom. Błędy topologii powodują zwykle wystąpienie pewnej liczby residuów przekraczających określony próg. Residua te związane są z danymi pomiarowymi odnoszącymi się do otoczenia źle uwzględnionego elementu sieci. Podobny efekt występuje w przypadku błędnych danych pomiarowych. Z tego powodu istnieją problemy z rozróżnieniem między błędnymi danymi a błędami topologii.

Residua nie dają informacji, pozwalającej na wykrycie błędów topologii dla elementów dla których brak jest danych pomiarowych.

Metody wykorzystujące wyniki estymacji stanu wymagają przeprowadzenia estymacji stanu nawet przy obecności błędów topologii. Jeśli nie będzie możliwe uzyskanie zbieżności procesu estymacji ze względu na istniejące błędy, nie będzie możliwe także przeprowadzenie weryfikacji topologii. Metody te są więc w dużym stopniu uzależnione od własności metody estymacyjnej i warunków pracy systemu. Lepsze pod tym względem własności wykazują metody wykorzystujące estymację najmniejszej wartości bezwzględnej i estymator M-Hubera.

Wiele metod zakłada modelowanie stacji elektroenergetycznej na poziomie węzła uogólnionego. Model taki jest tworzony przez procesor topologii na podstawie danych telesygnalizacji. Model stacji elektroenergetycznej staje się bardziej złożony, gdy stosuje się jej szczegółowe modelowanie. W takim przypadku konieczna jest odpowiednia liczba danych pomiarowych, w celu zachowania obserwowalności.

Metody oparte na analizie residuów są zwykle złożone obliczeniowo. W przypadku niektórych metod określone zostały warunki dla których nie jest możliwe wykrycie błędów topologii.

3.7.2. Metody wykorzystujące znormalizowane innowacje

Metody wykorzystujące tzw. znormalizowane innowacje korzystają z wyników dynamicznej estymacji stanu (*Forecast Aided State Estimation* – FASE) [40].

Wektor innowacji jest zdefiniowany jako:

$$\mathbf{v}_{k+1} = \mathbf{z}_{k+1} - h_{k+1}(\hat{\mathbf{x}}_{k+1}) \quad (3.32)$$

gdzie:

$\mathbf{z}_{k+1}$ – wektor danych pomiarowych w momencie czasu $k+1$,

$h_{k+1}(\hat{\mathbf{x}}_{k+1})$ – wektor predykcji danych pomiarowych dla chwili $k+1$.

Znormalizowany wektor innowacji wyraża się zależnością:

$$v_i^N = \frac{|v_i|}{\sigma_i}, \quad (3.33)$$

gdzie:

σ_i – standardowe odchylenie i -tego elementu wektora innowacji.

Metoda przedstawiona w [57] umożliwia detekcję i identyfikację wielokrotnych błędów topologii oraz błędnych danych. Dla sieci tworzony jest graf obwodu dla innowacji, do którego tworzenia wykorzystuje się zasadę superpozycji. W grafie innowacji źle uwzględniona gałąź stanowi źródło napięciowe. Wykrycie błędu topologii polega na rozwiązaniu liniowego obwodu i znalezieniu gałęzi dla których występuje największy prąd gałęziowy. Możliwe jest rozróżnienie między błędnymi danymi a błędami topologii. Metoda wykorzystuje dane pomiarowe dla mocy czynnej. Wymaga odpowiednio dużej liczby danych pomiarowych – metoda nie działa w przypadku, gdy część sieci jest nieobserwowalna. Działanie metody zależy od własności metody dynamicznej estymacji stanu i stanu pracy sieci.

Interesujące wykorzystanie wyników dynamicznej estymacji stanu i techniki sztucznych sieci neuronowych przedstawiono w [46], [47] oraz [48]. Błędy topologii lub nagła zmiana stanu pracy (wystąpienie nieprzewidzianych zdarzeń w prognozie stanu systemu elektroenergetycznego, np. odłączenie obciążenia) dotyczące określonego elementu systemu dotyczy niewielkiej części wektora znormalizowanych innowacji, tj. innowacji dla otoczenia tego elementu (lokalny charakter błędu topologii). Błędy topologii podzielono na dwa typy:

- typ A – sygnalizacja zmiany topologii, gdy w rzeczywistości ona nie wystąpiła,
- typ B – brak sygnalizacji zmiany topologii, gdy w rzeczywistości ona wystąpiła.

Oba typy mogą z kolei być podzielone na błędy:

- uwzględnienia gałęzi w rzeczywistości wyłączonej,
- nieuwzględnienia gałęzi w rzeczywistości załączonej.


W przypadku węzłów, błąd topologii występuje, gdy w modelu uwzględniona jest inna, niż w rzeczywistości, liczba węzłów.

Dla każdej z gałęzi zastosowano cztery sztuczne sieci neuronowe. Poszczególne sieci skojarzone z gałęzią $s-r$ spełniają następujące zadania:

- $SSN1_{s-r}$ – rozróżnienie między błędem typu A nieuwzględnienia gałęzi oraz nagłą zmianą stanu pracy spowodowaną wyłączeniem gałęzi,
- $SSN2_{s-r}$ – rozróżnienie między błędem typu A uwzględnienia gałęzi oraz nagłą zmianą stanu pracy spowodowaną załączeniem gałęzi,
- $SSN3_{s-r}$ – rozróżnienie między błędem typu B uwzględnienia gałęzi oraz zdarzeniami nie będącymi błędami typu B (duże błędy pomiarowe, nagłe zmiany obciążenia),
- $SSN4_{s-r}$ – rozróżnienie między błędem typu B nieuwzględnienia gałęzi zdarzeniami nie będącymi błędami typu B (duże błędy pomiarowe, nagłe zmiany obciążenia).

Dla stacji elektroenergetycznej s , w której jest możliwych m różnych konfiguracji połączeń metoda proponuje zastosowanie zbioru sztucznych sieci neuronowych służących do identyfikacji aktualnego układu połączeń. Dla każdej kombinacji zmiany konfiguracji połączeń, z układu p do q , zastosowane są dwie sieci neuronowe, które służą do identyfikacji błędów typu A ($SSNA_{s_{p-q}}$) i typu B ($SSNB_{s_{p-q}}$). W przypadku dużej liczby możliwych układów połączeń w stacji, konieczne jest uczenie dużej liczby sieci neuronowych

Algorytm detekcji i identyfikacji błędów przedstawiono na rys. 3.2. W przypadku sygnalizacji zmian topologii sprawdzane jest wystąpienie błędów typu A. W przypadku braku takiej sygnalizacji, tworzona jest, na podstawie znormalizowanych innowacji lista elementów systemu dla których mogły wystąpić zmiany. Następnie sprawdzana jest możliwość wystąpienia błędów topologii typu B. Do realizacji klasyfikatorów błędów topologii zastosowano sieci neuronowe jednokierunkowe realizujących wielomianowe odwzorowanie zmiennych wejściowych w zmienne wyjściowe. Wyniki testowania metody wskazują na możliwość wykrywania błędów topologii w warunkach niskiej redundancji pomiarowej a także w obecności błędnych krytycznych danych pomiarowych. Możliwe jest także rozróżnienie między wystąpieniem błędnych danych a błędem topologii. Metodę cechuje mała zależność od stanu pracy systemu. Działanie jest jednak uzależnione od charakterystyki dynamicznej estymacji stanu. Istnieje też konieczność uczenia dużej liczby sztucznych sieci neuronowych. Działanie metody przetestowano z wykorzystaniem systemu testowego IEEE-24 oraz IEEE-118.



Rys. 3.2. Schemat blokowy algorytmu wykrywania błędów topologii [46]

3.7.3. Podejście wykorzystujące „surowe” dane pomiarowe i telesygnaly

W ramach podejścia wykorzystującego do weryfikacji topologii „surowe” dane pomiarowe i telesygnaly wyodrębnić można następujące grupy metod:

- metody logiczno-heurystyczne,
- metody wykorzystujące techniki sztucznej inteligencji: systemy ekspertowe, inteligentne systemy hybrydowe, sztuczne sieci neuronowe.

Metody logiczno-heurystyczne

Jedną z pierwszych metod weryfikacji topologii, jest metoda [21]. W metodzie tej rozpatrywane są stany dwóch wyłączników na końcach gałęzi i wartość przepływu mocy czynnej. Stan każdego z wyłączników (załączony/wyłączony) sprawdzany jest pod względem zgodności z warunkami przepływu mocy. Jeśli zachodzi niezgodność, wtedy stan wyłącznika na drugim końcu służy do podjęcia ostatecznej decyzji. W przypadku zerowego przepływu przez gałąź, przy sygnalizowanym załączeniu wyłącznika, przyjmowany jest jego poprzedni stan.

Metoda jest bardzo prosta, jednak jej możliwości wykrywania różnych błędów topologii są ograniczone.

Metoda zaprezentowana w [17] opiera się na sprawdzaniu spełnienia związków opisujących stany wyłączników i dane pomiarowe mocy czynnej. Zależność dla gałęzi:

$$P_{ij} + b_{ji}P_{ji} = 0, \quad (3.34)$$

gdzie:

b_{ji} – zmienna binarna opisująca stan wyłącznika ($b_{ji} = 0$ – wyłącznik wyłączony, $b_{ji} = 1$ – wyłącznik załączony),

P_{ij}, P_{ji} – przepływy na końcach gałęzi łączącej węzły i, j .

Niespełnienie związków może wskazywać na obecność błędów topologii lub błędnych danych. Metoda sprawdza proste zależności, jednak może nie dostarczać poprawnych wyników weryfikacji topologii i wystąpienia błędnych danych, jeśli rozpatrywana jest większa liczba związków dla bardziej złożonych sieci. Charakterystyczna jest też zależność od parametrów gałęzi.

Przedstawiona w [7] metoda symuluje w prosty sposób zachowanie operatora. Specjalistyczna wiedza ujęta została w specjalnej tabeli sporządzonej dla każdego elementu sieci elektroenergetycznej. Opracowano funkcję *Strateg* w ramach której dostępne są trzy sposoby działania:

- eliminacja, ale nie poprawianie błędnych danych,

- eliminacja lub „ostrożne” korygowanie błędnych danych,
- analiza danych i, w razie potrzeby, ich modyfikacja zgodnie z wiedzą i doświadczeniem operatora.

Metoda przyjmuje probabilistyczne kryteria decyzyjne, tzn. na podstawie analizy systemu elektroenergetycznego określono prawdopodobieństwo zajścia określonego zdarzenia. Jest prosta do implementacji, umożliwia dobór strategii (sposobu) działania w zależności od stanu pracy systemu. Konieczne jest jednak pozyskanie odpowiedniej wiedzy dotyczącej systemu.

Zastosowanie algorytmu przeszukiwania grafu sieci elektroenergetycznej zaproponowano w [6]. Przy przeszukiwaniu dokonuje się kontroli poprawności danych poprzez sprawdzanie spełniania związków wynikających z prądowego i napięciowego prawa Kirchhoffa. Na podstawie wariancji danych pomiarowych wyznaczany jest margines tolerancji. Jeśli w oczku sieci suma spadków napięć wykracza poza ten margines lub bilans mocy przekracza dopuszczalny poziom, sygnalizowane jest niespełnienie zależności, zaś elementom sieci, z którym powiązane są niepoprawne dane, przydzielane są punkty karne. Tworzona jest następnie lista „podejrzanych” elementów, tj. elementów, co do których można wysunąć przypuszczenie, że są niewłaściwie uwzględnione w modelu. Zaletą tej metody jest prostota i możliwość zastosowania jej razem z estymacją stanu. Wadą jest wrażliwość na błędne dane pomiarowe. Autorzy wskazują na to, że efektywność metody znacznie wzrasta przy zastosowaniu dodatkowych analiz poprawiających dokładność danych pomiarowych. Przy konstruowaniu grafu przeszukiwań konieczna jest stosunkowo duża liczba danych pomiarowych przepływów. Efektywność metody pogarsza się, jeśli dominują dane pomiarowe dla mocy węzłowych.

Modyfikację przedstawionej metody zaproponowano w [29]. W trakcie przeszukiwania grafu sieci sprawdzane jest spełnienie bilansów mocy czynnej w węźle i poziom strat mocy czynnej w gałęzi. Wykrywanie błędów topologii jest przeprowadzane modyfikacją topologii sieci otaczającej węzeł dla którego wystąpiły różnice między danymi pomiarowymi mocy czynnej węzłowej a wartością mocy wyznaczoną obliczeniowo. W celu wykrycia błędu polegającego na uwzględnieniu w modelu gałęzi w rzeczywistości wyłączonej przeprowadza się test admitancji gałęzi. Gdy wyznaczona admitancja nie przekracza pewnej wartości progowej, gałęź uznawana jest za wyłączoną.

Zastosowanie wskaźników wrażliwych na występowanie niezgodności między danymi pomiarowymi a topologią systemu przedstawiono w [33]. Przykładowo, wskaźnik dla mocy biernej jest liniowo zależny od wartości przepływu mocy:

$$RQ_{i-j} = aQ_{i-j} + b, \quad (3.35)$$

gdzie:

RQ_{i-j} – wskaźnik dla przepływu mocy biernej w gałęzi $i-j$,

Q_{i-j} – przepływ mocy biernej w gałęzi $i-j$,

a, b – współczynniki.

W przypadku zerowego przepływu w gałęzi przyjmuje się wystąpienie błędnej danej ($RQ_{i-j} = b$) lub błędu topologii ($RQ_{i-j} \neq b$).

Zastosowanie systemów ekspertowych

Zaproponowana w [44] i [43] metoda symuluje zachowanie eksperta poprzez sprawdzanie spełnienia różnego rodzaju reguł podzielonych na cztery podstawowe grupy:

- częściowe, dostępne informacje dotycząca stanów wyłączników,
- informacje o wzajemnych zależnościach między:
 - a) stanami wyłączników a danymi pomiarowymi,
 - b) stanami wyłączników a stanami pozostałych wyłączników,
- związki uwzględniające zależności czasowe,
- inne informacje nt. określonej sieci, nie uwzględnione powyżej.

Proponowany system zawiera ok. 120 reguł.

Metoda jest prosta, łatwa do praktycznej implementacji, dostarcza poprawnych wyników dla różnych stanów pracy sieci. Jednakże autorzy wskazali na trudności w przypadku wystąpienia podziału węzła oraz z węzłami gdzie występują zerowe przepływy mocy.

Zastosowanie inteligentnych systemów hybrydowych

Zastosowanie rozmytego systemu ekspertowego dla potrzeb detekcji i identyfikacji błędów topologii przedstawiono w [20]. Z pomocą zbiorów rozmytych opisane zostały:

- dane pomiarowe przepływów mocy,
- zmiany przepływów mocy,
- dokładność pomiarów,
- stany wyłączników.

Wzorując się na [44] w bazie reguł zdefiniowano ich ok. 180. Stan wyłącznika określa się na podstawie wartości $\varphi(k)$ opisującej stan wyłącznika:


$$\varphi(k) = \frac{[\mu(z) + \mu(\Delta z_i)]\alpha_i + \beta_i}{n} \quad (3.36)$$

gdzie:

- $\mu(z)$ – funkcja przynależności dla pomiaru z ,
- $\Delta\mu(z_i)$ – funkcja przynależności zmian przepływów mocy,
- α_i, β_i – tzw. poziomy ufności związane z dokładnością danych pomiarowych,
- n – liczba reguł dla wyłącznika k użytych we wnioskowaniu.

W zależności od przedziału w jakim znajduje się wartość $\varphi(k)$ podejmowana jest decyzja o stanie wyłącznika.

Proponowana metod jest prosta w implementacji. Konieczne jest jednak zabranie odpowiedniej wiedzy specjalistycznej i określenie reguł. Ewentualne zmiany w strukturze sieci powodują konieczność modyfikacji dotychczasowych reguł i faktów.



Rys. 3.3. Struktura systemu ekspertowego z wykorzystaniem sztucznych sieci neuronowych

Problem z pozyskiwaniem wiedzy próbuje się rozwiązać stosując kombinację systemów ekspertowych i sztucznych sieci neuronowych. Funkcje systemu ekspertowego może spełniać system, który jest zdolny nauczyć się rozwiązywać pewne problemy. W przypadku klasycznych systemów konieczne jest pozyskiwanie wiedzy, ustalanie, modyfikacja i użycie odpowiednich reguł. Zastosowanie dodatkowo sztucznych sieci neuronowych pozwala na to, że system na bazie przykładów sam jest w stanie określić wszystkie te składniki. Przykład wykorzystania takiego systemu ekspertowego do detekcji błędów topologii przedstawiono w [51]. Jego strukturę przedstawia rys. 3.3. System składa się z dwóch części: bazy reguł oraz podsystemu sztucznych sieci neuronowych, który ma za zadanie dobór architektury sieci neuronowych, przechowywanie danych je opisujących a także przeprowadzenie uczenia. Aby system mógł odpowiednio działać, konieczne jest stworzenie odpowiednich zbiorów uczących

dla sieci neuronowych, uwzględniających możliwie pełny zestaw różnego rodzaju przypadków. Możliwe jest douczanie systemu na bazie przypadków dotąd nie uwzględnionych. Poprzez douczanie wiedza zgromadzona w sieciach neuronowych staje się coraz bardziej kompletna, co wpływa na efektywność działania całego systemu. W bazie danych sieci neuronowych przechowywanych jest szereg sieci neuronowych. W praktyce byłoby niemożliwe zastosowanie jednej dużej sieci neuronowej dla całego systemu.

Metoda wymaga odpowiednich zbiorów uczących, których tworzenie jest często kłopotliwe. System ma jednak możliwość uczenia się i poprawy rozwiązywania zadania.

Zastosowanie sztucznych sieci neuronowych

Wykorzystanie faktu wzajemnego powiązania wartości danych pomiarowych i topologii sieci oraz możliwość przyporządkowania zestawów danych wejściowych do grup odpowiadających poszczególnym konfiguracjom połączeń, stało się podstawą do opracowania metod weryfikacji topologii systemu elektroenergetycznego opartych na klasyfikacji wzorców z wykorzystaniem sztucznych sieci neuronowych.

W [4] przedstawiono wykorzystanie sztucznych sieci neuronowych do określania topologii systemu elektroenergetycznego. Jako zmiennych wejściowych użyto znormalizowanych danych pomiarowych mocy czynnej i stany wyłączników. Ponieważ w rzeczywistych systemach istnieje duża liczba tego typu danych, w celu ograniczenia ilości zmiennych wejściowych a przez to i uproszczenia samej sieci neuronowej, zastosowano dekompozycję sieci. Dodatkowo przeprowadzono analizę danych wejściowych pod kątem określenia ich cech (np. liniowa zależność niektórych zmiennych), przez co możliwe okazało się uzyskanie bardziej spójnego zbioru danych wejściowych. Przykładowo, sieć neuronowa opracowanej dla systemu testowego IEEE-24 (liczącego 24 węzły) liczyła 42 wejścia. W procesie uczenia uwzględniono szereg możliwych układów połączeń w systemie, możliwość występowania błędnych danych pomiarowych i telesygnalizacji a także przypadki w których występuje nieobserwowalność części systemu. Testy wykazały na możliwość poprawnej klasyfikacji nawet przy obecności błędnych danych. Niemożliwe okazało się poprawne określenie topologii dla gałęzi o charakterze reaktancyjnym – sieć neuronowa, wykorzystując jedynie dane pomiarowe dla mocy czynnej nie była w stanie dokonać poprawnej klasyfikacji. Konieczność zmniejszenia liczby zmiennych wejściowych, po aby uprościć sieć neuronową i umożliwić jej działanie wpływa także na ograniczenie liczby informacji o systemie.

Autorzy wskazują także na możliwość połączenia sztucznych sieci neuronowych i systemu ekspertowego. Wykorzystanie własności obu technik wpłynęłoby, zdaniem autorów, na uzyskanie lepszych własności, niż stosowanie osobno każdej z technik.

Zastosowanie różnego typu sieci neuronowych do określania topologii oraz estymacji stanu systemu elektroenergetycznego przedstawiono w [52], [53]. Porównano własności:

- sieci neuronowej o propagacji przeciwniej (*Counter Propagation*),
- sieci połączeń funkcyjnych (*Functional Link Network*).

Wyniki badań wskazują na lepsze własności sieci o propagacji przeciwniej w zakresie określania topologii. Klasyfikator potrafił poprawnie przeprowadzić określenie topologii także w przypadku obecności błędnych danych. Podobnie jak w [4] jako zmiennych wejściowych dla sieci neuronowej użyto dane pomiarowe dla mocy czynnej i stany wyłączników.

Uwzględnienie znacznie większej liczby zmiennych wejściowych dla klasyfikatora topologii z wykorzystaniem sieci neuronowej zaproponowano w [1]. Zbiór danych wejściowych obejmuje:

- numer gałęzi,
- numer węzła początkowego i końcowego gałęzi,
- przepływy mocy czynnej i biernej na końcach gałęzi,
- wartość prądu gałęziowego,
- stany wyłączników na końcach gałęzi.

Zastosowano sieć neuronową, wielowarstwową, typu *feedforward* (jednokierunkową). Testowanie przeprowadzono dla sieci testowej 9-węzłowej. Wykorzystanie tak dużej liczby zmiennych powoduje jednocześnie komplikację struktury sieci neuronowej, związane z tym problemy z uczeniem i działaniem. Dlatego zastosowanie rozwiązania jest ograniczone jedynie dla systemów o niewielkich rozmiarach.

Podobną metodę zaprezentowano w [12]. Zmiennymi wejściowymi dla sieci neuronowej określającej topologię są dane pomiarowe mocy czynnej i stany wyłączników. Badanie metody przeprowadzono dla systemu testowego IEEE-24. W zbiorze uczącym dla sieci neuronowej uwzględniono 40 różnych konfiguracji połączeń sieci, różne poziomy obciążenia oraz możliwość wystąpienia błędnych danych pomiarów i telesygnalizacji. Testowanie przeprowadzono dla różnych grup danych z różniących się ilością błędnych danych. Wraz ze wzrostem ilości błędnych danych zwiększała się także ilość niepoprawnych klasyfikacji. Metoda jest w stanie poprawnie określić topologię tylko w dla ograniczonej liczby przypad-

ków. Podobnie jak w przypadku innych metod ([1], [4], [52], [53]), architektura sieci neuronowej klasyfikatora topologii zależy od rozmiarów systemu elektroenergetycznego.

Interesującą metodę wykorzystującą sztuczne sieci neuronowe przedstawiono w [18]. Dokonywane jest określanie topologii systemu elektroenergetycznego, zaś informacja o niej może zostać wykorzystana do potrzeb weryfikacji. System złożony jest z dwóch podstawowych bloków:

- lokalny klasyfikator topologii – realizuje wstępne przetwarzanie danych pomiarowych mocy czynnej i biernej a następnie dokonuje klasyfikacji do odpowiedniej grupy odpowiadającej określonej topologii. W stopniu wstępnego przetwarzania, wykorzystującego sieć o radialnej funkcji bazowej (RBF – *Radial Basis Function*), każdy neuron realizuje sumowanie różnych kombinacji danych pomiarowych mocy czynnej i biernej dla danego węzła i ich klasyfikację zgodnie z radialną funkcją aktywacji. Do realizacji klasyfikatora lokalnego zastosowano 3-warstwą sztuczną sieć neuronową z sigmoidalną, bipolarną funkcją aktywacji,
- globalny klasyfikator topologii – gromadzi wyniki klasyfikacji z poszczególnych, skojarzonych z poszczególnymi węzłami sieci, lokalnych klasyfikatorów i generuje na tej podstawie ostateczną informację o topologii systemu.

Dzięki zastosowaniu lokalnych klasyfikatorów, uniknięto problemów związanych z tworzeniem jednej, złożonej sieci neuronowej dla całego systemu. Proces uczenia sieci neuronowych został sprowadzony do uczenia szeregu sieci o stosunkowo prostej architekturze. Wyniki testowania wskazują na dużą efektywność w wykrywaniu jednokrotnych i wielokrotnych błędów topologii nieuwzględnienia gałęzi, niezależność od zmian poziomu obciążenia w systemie elektroenergetycznym. Metoda wymaga jednak dysponowania pełnym zestawem danych pomiarowych przepływów mocy. W przypadku małych wartości przepływu mocy w załączonej gałęzi, możliwe jest uwzględnienie jej w modelu jako wyłączonej.

W [19] przedstawiono modyfikację metody polegającą na wykorzystaniu klasyfikacji kombinacji sum danych pomiarowych jedynie dla mocy czynnej oraz zastosowaniu jako klasyfikatorów lokalnych sieci neuronowych z funkcją potencjału Gaussa jako funkcją aktywacji wyrażoną zależnością:

$$y_i(\mathbf{x}) = \exp\left[-(\mathbf{x} - C_i)H(\mathbf{x} - C_i)^T\right], \quad (3.37)$$

gdzie:

$\mathbf{x}$ – wektor wyników wstępnej klasyfikacji kombinacji sum danych pomiarowych mocy czynnej,

C_i – wektor centrów grupy danych i ,

H – diagonalna macierz wagowa.

Klasyfikator lokalny, skojarzony z węzłem systemu elektroenergetycznego, określa stopień przynależności wektora x do określonej topologii i opisanej za pomocą wektora C_i . Podobnie, jak w przypadku poprzedniej metody, uzyskano dużą efektywność w wykrywaniu błędów topologii. Niemożliwe jest jednak wykrycie nieprawidłowego uwzględnienia gałęzi o charakterze reaktancyjnym. Metoda jest wrażliwa na występowanie błędów danych pomiarowych oraz niekompletność ich zbioru.

Do testowania metod opisanych w [18] i [19] wykorzystano system testowy IEEE-14.

Zestawienie najważniejszych właściwości metod wykorzystujących „surowe” dane pomiarowe i telesygnały

Podejście wykorzystujące „surowe” dane pomiarowe i telesygnały umożliwia przeprowadzenie weryfikacji topologii systemu elektroenergetycznego przed estymacją stanu i nie korzysta z jej wyników. Metody logiczno-heurystyczne opierają się na sprawdzaniu prostych związków i zależności, nie są też wymagające obliczeniowo. Mają jednak ograniczone możliwości wykrywania błędów topologii. Możliwości te zmniejszają się, gdy występują błędne dane, lub zbiór danych pomiarowych jest niekompletny.

Metody wykorzystujące systemy z bazą wiedzy są proste i możliwe jest ich praktyczne zastosowanie. Wymagają jednak dużego nadmiaru danych pomiarowych. W prostszych rozwiązaniach W prostszych rozwiązaniach mają ograniczone możliwości. Jakość weryfikacji znacznie się pogarsza w obecności błędów obarczających dane pomiarowe.

Weryfikacja topologii może być traktowana jako problem klasyfikacji. W związku z tym możliwe jest wykorzystanie sztucznych sieci neuronowych, co pozwala na proste i szybkie wykrywanie błędnie uwzględnionych stanów łączników. Sieci neuronowe wykazują zdolność do odnajdywania reguł łączących dane pomiarowe wielkości analogowych i dyskretne stany łączników. Dzięki właściwościom uogólniania nie jest wykluczone dostarczanie poprawnych wyników w przypadku obecności błędów obarczających dane pomiarowe i nieobserwowalności części systemu.

W rzeczywistych sieciach elektroenergetycznych występuje zwykle duża liczba telemiary i telesygnali, tj. danych pomiarowych wielkości analogowych i danych o stanach łączników. Przy tak dużej liczbie zmiennych stworzenie jednego klasyfikatora dla całej sieci jest zadaniem niezwykle trudnym, lub niewykonalnym (tzw. „przekleństwo wielowymiarowości”). Zastosowanie technik dekompozycji sieci, czy też dodatkowej analizy danych

z wykorzystaniem posiadanej wiedzy teoretycznej w celu redukcji liczby zmiennych uwzględnionych przez jedną sieć neuronową, jest sposobem na rozwiązanie problemu.

Wykorzystanie w szerszym zakresie różnych związków obowiązujących w systemie, elektroenergetycznym efektu lokalności błędu topologii prowadzi do istotnej poprawy efektywności wykrywania błędów topologii systemu elektroenergetycznego.

3.7.4. Podsumowanie

Początkowo, metody weryfikacyjne wykorzystywały sprawdzanie bardzo prostych związków oraz analizę residuów pomiarowych. Ostatnie lata przyniosły wzrost zainteresowania zastosowaniem technik sztucznej inteligencji, a zwłaszcza techniki sztucznych sieci neuronowych.

Nie można jednoznacznie wskazać na metodą, która jednocześnie dysponowałaby wszystkimi pożądanymi cechami. Analiza istniejących metod weryfikacji topologii pokazuje, że metody wykorzystujące sztuczne sieci neuronowe nie dysponują jeszcze w pełni wymaganymi własnościami. Należy jednak zauważyć, że stosowanie tych technik daje możliwości, które nie zostały jeszcze wzięte pod uwagę. Szczególnie jest to widoczne w zakresie wykorzystania sztucznych sieci neuronowych. W dotychczasowych badaniach daje się zauważyć tendencje do opracowywania metod, które zakładają:

- wykorzystanie wielu sztucznych sieci neuronowych odnoszących się do poszczególnych fragmentów sieci elektroenergetycznej, czyli wyciągnięcie wniosków z lokalnego charakteru błędu topologii,
- uwzględnienie danych pomiarowych przepływów mocy czynnej,
- uwzględnienie związków pomiędzy danymi pomiarowymi mocy czynnej, wynikających z pierwszego prawa Kirchhoffa, czyli związków dla węzłów sieci elektroenergetycznej,

Jak do tej pory nie podano w literaturze metody opartej na wykorzystaniu sztucznych sieci neuronowych, która by:

- możliwie jak najbardziej ograniczała obszar sieci elektroenergetycznej przez jedną sztuczną sieć neuronową, tj. ograniczałaby ten obszar do najbliższego sąsiedztwa węzła, z którym byłaby związana jedna sieć neuronowa,
- brała pod uwagę zbiór danych pomiarowych przepływów mocy czynnej oraz mocy biernej i poziomów napięć, a więc dane dostępne w Krajowej Dyspozycji Mocy,
- uwzględniała związki pomiędzy wspomnianymi wcześniej wielkościami, które można wyznaczyć nie tylko dla węzłów ale także dla gałęzi sieci elektroenergetycznej.

Należy oczekiwać, że metoda, która by uwzględniała wszystkie wymienione elementy będzie miała o wiele korzystniejsze właściwości aniżeli dotychczas spotykane w literaturze.

4. Techniki sztucznej inteligencji

4.1. Wprowadzenie

W ostatnich latach obserwowany jest wzrost zainteresowania wykorzystaniem technik sztucznej inteligencji w różnych dziedzinach nauki i techniki, w tym także z zagadnieniami związanych z systemami elektroenergetycznymi [37]. Do technik sztucznej inteligencji zalicza się:


- sztuczne sieci neuronowe (*Artificial Neural Networks*),
- systemy ekspertowe (*Expert Systems*)
- logikę rozmytą (*Fuzzy Logic*),
- algorytmy genetyczne (*Genetic Algorithms*),
- algorytm symulowanego wyżarzania (*Simulated Annealing*).

Często stosuje się systemy hybrydowe będące kombinacją różnych wymienionych technik. Pozwala to na wykorzystanie tych cech każdej z technik składowych, które są najbardziej pożądane i użyteczne dla danego problemu.

4.2. Sztuczne sieci neuronowe

4.2.1. Wprowadzenie

Idea wykorzystania sztucznych sieci neuronowych powstała w wyniku analizy działania komórek nerwowych człowieka i zwierząt. Modelem procesów zachodzących w strukturach biologicznych jest sieć podstawowych elementów, tzw. neuronów, przetwarzających informację i powiązanych ze sobą połączeniami. Model pojedynczego neuronu przedstawia rys. 4.1. Sygnał wyjściowy neuronu jest funkcją sumy $f(u_i)$ sygnałów wejściowych $x_1 - x_n$ o odpowiednich wagach $w_{i1} - w_{iN}$ oraz pewnej stałej wartości w_{i0} .

Rys. 4.1. Model neuronu z funkcją aktywacji $f(u_i)$.

Działanie pojedynczego neuronu można zależnością:

$$y_i = f(u_i) = f\left(\sum_{j=0}^N w_{ij} x_j\right), \quad (4.1)$$

gdzie:

y_i – wyjście neuronu i ,

$f(\bullet)$ – funkcja aktywacji neuronu,

w_{ij} – współczynnik wagowy (waga) połączenia między neuronem i oraz j ,

x_j – wartość wejściowa pochodząca z neuronu j .

4.2.2. Modele komórek neuronowych

Opracowano wiele modeli matematycznych neuronów, zaś do najczęściej wykorzystywanych należą [36], [50], [59]:

- perceptron – w modelu tym zastosowano nieliniową funkcję aktywacji typu skokowego (funkcja Heaviside'a),
- neuron sigmoidalny – jest podobny do perceptronu, z tym, że funkcją aktywacji jest funkcja sigmoidalna unipolarna lub bipolarna,
- neuron typu *Adaline* – posiada skokową funkcję aktywacji, jednak jest uważany za element liniowy, gdyż w procesie uczenia tego typu neuronu człon nieliniowy funkcji aktywacji jest pominięty,
- neurony typu *Instar* i *Outstar* – w procesie uczenia tego typu neuronów wagi dopasowują się do wartości wejściowych lub wyjściowych,
- neuron Hebb'a – zmiana wagi neuronu a połączonego z neuronem b jest proporcjonalna do iloczynu jego sygnału wejściowego i wyjściowego,

- neuron typu WTA (*Winner Takes All* – zwycięzca bierze wszystko) – w grupie neuronów występuje współzawodnictwo. Dla każdego neuronu wyznaczana jest ważona suma sygnałów wejściowych. Neuron "zwycięzca", tj. tak, dla którego wartość sumy jest największa, jest uaktywniany. Aktualizowane są tylko wagi neuronu zwycięzcy. Proces ten jest powtarzany, aż sieć neuronowa nauczy się pewnego problemu.

Ze względu na sposób wzajemnych połączeń między neuronami wyróżnić można:

- sieć neuronowa jednokierunkowa wielowarstwowa (*Multilayer Feedforward*) – sygnały przesyłane są w jednym kierunku, zaś połączenia występują tylko między sąsiednimi warstwami. Architektura ta jest w praktyce stosowana najczęściej,
- sieć neuronowa rekurencyjna (*Counterpropagation*) – sygnały przesyłane są w dwóch kierunkach,
- sieć komórkowa – poszczególne neurony połączone są tylko z sąsiednimi neuronami.

4.2.3. Typy sieci neuronowych

Opracowano wiele typów sieci neuronowych uwzględniając różną architekturę, typy neuronów, specyfikę działania i funkcje jakie dana sieć ma spełniać. Do najczęściej wykorzystywanych w praktyce typów sieci zaliczyć można:

- sieci jednokierunkowe wielowarstwowe z algorytmem propagacji wstecznej błędu (*Multi-layer Perceptron with Backpropagation*) – wykorzystywane są głównie do realizacji zadań klasyfikacyjnych. Są najczęściej wykorzystywanym typem sieci,
- sieci z radialną funkcją bazową (*Radial Basis Function* – RBF) – neurony sieci tego typu realizują funkcję zmieniającą się radialnie wokół wybranego centrum i przyjmującą wartości niezerowe tylko wokół tego punktu. Sieci tego typu używane są do zadań klasyfikacji i aproksymacji,
- samoorganizująca się sieć odwzorowań Kohonena – sieć ta wykorzystuje zasadę "zwycięzca bierze wszystko". W procesie uczenia sieć uczy się przestrzennego rozkładu danych wejściowych, tworząc ich mapy stanowiące oddzielne grupy. Znajdują zastosowanie w kompresji danych, prognozowaniu, aproksymacji, klasyfikacji,
- sieć Hopfielda – jest typem sieci rekurencyjnej gdzie tworzone są połączenia wejść z wyjściami pojedynczych neuronów jak i całej sieci. Sieć nie posiada jednoznacznie określonej architektury. Osiągnięcie docelowego stanu sieci polega na minimalizacji zdefiniowanej funkcji energii. Sieci Hopfielda stosuje się do rozwiązywania zagadnień optymalizacyjnych a także jako pamięć autoskojarzeniową (odtworzenie na zasadzie skojarzeń całości informacji na podstawie dostępnego jej fragmentu),

- sieć ART-1 (*Adaptive Resonance Theory*) – jest typem sieci samoorganizującej się. Uczenie odbywa się w trybie nienadzorowanym. Wagi zapisane są w dwóch grupach odpowiadających pamięci krótkotrwałej i długotrwałej. W czasie uczenia kolejno podawane obrazy wejściowe klasyfikowane są do jednej z istniejących grup, gdy obraz wejściowy jest podobny do jednej z już istniejącej grupy obrazów (sieć jest w rezonansie). W przypadku rozbieżności tworzona jest nowa grupa. Sieci ART.-1 stosuje się do klasyfikacji obrazów binarnych,

Do innych, rzadziej wykorzystywanych typów sieci, należą: sieć Counterpropagation, sieci komórkowe, sieć Hintona, sieć BAM (*Bidirectional Associative Memory*) i in.

4.2.4. Uczenie sieci neuronowych

W przypadku sztucznych sieci neuronowych wyróżnia się dwa rodzaje uczenia:

- uczenie nadzorowane,
- uczenie nienadzorowane.

W przypadku uczenia nadzorowanego zbiór uczący, składa się z zestawu danych podawanych na wejście oraz na wyjście. Wagi sieci neuronowej są tak modyfikowane, aby osiągnąć na wyjściu sieci pożądaną odpowiedź, tj. aby różnica między oczekiwaną wartością na wyjściu a wartością nauczoną nie przekroczyła pewnej ustalonej wartości. Stosuje się różne reguły i algorytmy uczenia w zależności od typu sieci neuronowej.

W uczeniu nienadzorowanym wartości na wyjściu sieci nie są znane i określane są dopiero w trakcie uczenia. Sieć uczy się poprzez modyfikację swoich parametrów analizując reakcję na nieznane wcześniej dane wejściowe. W ten sposób dokonywana jest klasyfikacja danych wejściowych do pewnych grup.

4.2.5. Własności sztucznych sieci neuronowych

Sztuczne sieci neuronowe stosuje się do rozwiązywania szeregu różnych problemów. Do głównych cech, dzięki którym są one najczęściej stosowaną techniką spośród technik sztucznej inteligencji, zaliczyć można:

- możliwość nabywania wiedzy na temat danego problemu na drodze uczenia. Wiedza o danym zagadnieniu przechowywana jest w architekturze sieci, wartościach współczynników wagowych i interpretacji nadanych poszczególnym wejściom i wyjściom,
- zdolność uogólniania – sieć wyuczona na zbiorze uczącym generuje poprawne wyniki także przy podaniu na jej wejście zbioru danych nie uwzględnionego w procesie uczenia,

- możliwość odnajdywania zależności łączących zbiór danych wejściowych i wyjściowych w przypadkach, gdy postać analityczna związku jest niemożliwa lub bardzo trudna do ustalenia,
- zdolność do odnajdywania cech –sieci neuronowe posiadają możliwości analizowania danych, np. filtracji zniekształconej informacji, ograniczenie wymiaru danych itp.
- zdolność do rozpoznawania i klasyfikacji – sieci neuronowe umożliwiają identyfikację wzorca i przyporządkowanie go do określonej klasy,
- możliwość poprawnego działania w przypadku gdy część informacji wejściowej jest zniekształcona bądź niekompletna,
- równoległy, a przez to bardzo szybki, sposób przetwarzania informacji.

4.2.6. Zastosowanie sztucznych sieci neuronowych w elektroenergetyce

Sieci neuronowe znalazły szerokie zastosowanie w zagadnieniach związanych z systemami elektroenergetycznymi, wśród których można wymienić:


- prognozowanie krótkoterminowe obciążeń w systemie elektroenergetycznym,
- planowanie rozwoju sieci,
- detekcja, lokalizacja i klasyfikacja zwarć,
- detekcja błędnych danych pomiarowych,
- estymacja stanu systemu elektroenergetycznego,
- funkcje alarmowania, monitorowania,
- ocena stabilności napięciowej systemu,
- regulacja napięcia i częstotliwości generatorów,
- przetwarzanie sygnałów pomiarowych.

4.3. Systemy ekspertowe

System ekspertowy jest jedną z form systemów z bazą wiedzy. Wśród wielu istniejących definicji systemu ekspertowego przytoczyć można następującą: system ekspertowy ujmuje wiedzę eksperta w specjalistycznej dziedzinie wiedzy w formie przystosowanej do przetwarzania w systemie komputerowym. System wykorzystuje wiedzę w celu zapewnienia wspomagania podejmowania decyzji na poziomie porównywalnym do człowieka-eksperta. Jest także zdolny do oceny tego rozumowania. Mechanizmy wnioskowania są oddzielone od wiedzy na temat danej dziedziny i stosuje jedną lub więcej struktur reprezentacji tej wiedzy.

System ekspertowy próbuje naśladować człowieka-eksperta w operowaniu symbolami oraz informacją niepewną lub nieznaną, wyjaśnianiu i dostarczaniu konkluzji wielowartościowych.

Proces konstruowania systemów ekspertowych należy do tzw. inżynierii wiedzy, której zadaniem jest pozyskiwanie wiedzy, określenie odpowiednich metod wnioskowania i wyjaśniania, konstrukcja interfejsu użytkownika. Schemat blokowy systemu ekspertowego przedstawiono na rys. 4. 2.



Rys. 4.2. Schemat blokowy systemu ekspertowego

Użytkownik komunikuje się z systemem ekspertowym za pośrednictwem interfejsu użytkownika. System wnioskowania, tzw. maszyna wnioskująca, przetwarza informację od użytkownika, a także informację z bazy wiedzy. Wyniki przetwarzania na wyjściu maszyny wnioskującej prezentowany użytkownikowi.

Z konstruowaniem i stosowaniem systemów ekspertowych wiąże się szereg problemów:

- ograniczenia wynikające z bazy wiedzy – efektywność systemu ekspertowego zależy w znacznej mierze od ilości i jakości wiedzy specjalistycznej na temat danego zagadnienia,
- trudna do wykrycia niekompletność danych w bazie wiedzy,
- możliwość wystąpienia redundancji danych
- problemy z wnioskowaniem w warunkach niepewności

Obszary zastosowań systemów ekspertowych w elektroenergetyce:

- planowanie rozwoju systemu,

- działanie systemu: diagnostyka zwarć, funkcje alarmowania, wyznaczanie procedur łączeniowych, prognozowanie obciążeń, planowanie remontów, regulacja napięcia i mocy biernej, odbudowa systemu,
- analiza: projektowanie systemów automatyki i sterowania, diagnostyka urządzeń.

4.4. Logika rozmyta


Za pomocą zbiorów rozmytych możliwe jest formalne przedstawienie pojęć nieprecyzyjnych i wieloznacznych, których nie można opisać za pomocą klasycznej logiki dwuwartościowej. W szerszym sensie, logika rozmyta jest synonimem teorii zbiorów rozmytych. W teorii zbiorów rozmytych operuje się pojęciami zmiennych lingwistycznych. Zgodnie z teorią zbiorów rozmytych z każdą zmienną x jest związana funkcja przynależności $\mu_A(x)$, wskazująca na stopień przynależności zmiennej x do zbioru A w zakresie wartości od 0 (tj. brak przynależności) do 1 (pełna przynależność). Zbiór rozmyty A w pewnej przestrzeni $\mathbf{X}$ wyrazić można za pomocą pary uporządkowanej:

$$A = \{(x, \mu_A(x)); x \in \mathbf{X}\}. \quad (4.2)$$

Kształt i parametry funkcji przynależności mogą mieć różną postać w zależności od specyfiki problemu.

Schemat wnioskowania rozmytego z wykorzystaniem wielu reguł wnioskowania przedstawiono na rys. 4.3. Wnioskowanie rozmyte polega na sposobie rozpatrywaniu rozmytej implikacji zbioru reguł rozmytych. Zmienne wejściowe i wyjściowe mają określoną swoją funkcję przynależności. Zbiory danych wejściowych są przekształcane w zbiory rozmyte zgodnie z funkcją przynależności. Działanie defuzyfikatora polega na ustalaniu konkretnej wartości zmiennej wyjściowej na podstawie wyników wielu rozmytych wnioskowań. Istnieją także systemy wnioskowania generujące bezpośrednio wielkości nierozmyte.

Systemy wykorzystujące logikę rozmytą znajdują zastosowanie w nieliniowych układach sterowania. Logika rozmyta nie nadaje się jednak do problemów diagnostycznych, gdzie konieczne jest separowanie poszczególnych przypadków, nie zaś ich interpolacja. W systemach elektroenergetycznych zbiory rozmyte znalazły zastosowanie w takich dziedzinach, jak: planowanie sieci elektroenergetycznych, modelowanie i sterowanie elektrowni, ocena bezpieczeństwa systemu elektroenergetycznego.



Rys. 4.3. Schemat wnioskowania w systemie rozmytym z n regułami wnioskowania.

4.5. Algorytmy genetyczne

Algorytmy genetyczne są metodą optymalizacji wzorowaną na naturalnej ewolucji. Dokonują one przeszukiwania opartego na prawach rządzących doбором naturalnym i dziedziczeniem.

Algorytmy genetyczne przedstawiają parametry zadania optymalizacji w zakodowanej postaci. Punktem wyjścia dla przeszukiwania jest pewna wybrana losowo populacja. Korzystają one z funkcji celu, zaś reguły wyboru są losowe. Algorytmy te operują na ciągach liczb binarnych zwanych osobnikami lub chromosomami. Dla każdego chromosomu określone jest jego przystosowanie, tzn. wartość funkcji przystosowania $f: \{0, 1\}^n \rightarrow \mathbf{R}$ (gdzie: n – długość ciągu) będącej pewnym odpowiednikiem funkcji celu. Chromosomy podlegają selekcji – do dalszej reprodukcji są wybierane jedynie te najlepiej przystosowane, tj. te dla których funkcja przystosowania ma największą wartość. Następna populacja chromosomów jest tworzona przez użycie operacji genetycznych a także obliczana jest wartości funkcji przystosowania każdego chromosomu w populacji. Do najczęściej wykorzystywanych operacji genetycznych należą: selekcja, krzyżowanie, mutacja. Operacje krzyżowania i mutacji nazywane są operatorami rekombinacji.

Zadaniem operacji selekcji jest utworzenie nowej populacji (pokolenia) przez wybór najlepiej przystosowanych osobników, tj. takich, dla których funkcja przystosowania przybiera największą wartość.

Niektóre chromosomy z nowej populacji podlegają rekombinacji za pomocą operacji krzyżowania i mutacji. W operacji krzyżowania tworzy się nowe osobniki przez połączenie części kilku osobników. Mechanizmy selekcji są proste i sprowadzają się do generacji liczb losowych, kopiowania łańcuchów i wymiany części łańcuchów.

W operacji mutacji tworzone są nowe osobniki poprzez niewielką zmianę w pojedynczym osobniku. Mutacja jest w istocie błędzeniem przypadkowym w przestrzeni rozwiązań.

Do cech algorytmów genetycznych należą:

- użycie losowych, nie zaś deterministycznych reguł przy przechodzeniu z jednego rozwiązania do drugiego,
- przeprowadzanie operacji na zakodowanych reprezentacjach problemu, jednakże ocena poszczególnych rozwiązań wymaga ponownego zdekodowania w celu wyznaczenia funkcji przystosowania.

Algorytmy genetyczne pozwalają na prowadzą zwykle do rozwiązywania złożonych problemów. Możliwe jest ich wykorzystanie razem z innymi metodami optymalizacji. Dają dobre rezultaty w przypadku problemów dla których metody iteracyjne prowadzą do osiągnięcia lokalnych optimum. Dzięki operowaniu na zakodowanej postaci problemu możliwe jest ich wykorzystanie do rozwiązywania problemów, gdzie klasyczne metody zawodzą, np. występowanie nieciągłości, brak pochodnej, wielomodalność, itp.

Algorytmy genetyczne znalazły zastosowanie w takich zagadnieniach związanych z systemami elektroenergetycznymi, jak:

- planowanie rozwoju sieci elektroenergetycznych,
- prognozowanie obciążeń krótkoterminowych,
- wyznaczanie ekonomicznego rozdziału obciążeń,
- optymalizacja konfiguracji sieci w celu minimalizacji strat,
- dobór składu jednostek.

4.6. Algorytm symulowanego wyżarzania

Symulowane wyżarzanie (*Simulated Annealing*), podobnie jak algorytmy genetyczne, może służyć do rozwiązywania problemów optymalizacyjnych. Idea oparta o analogię do fizycznego procesu krystalizacji. Ciało podgrzane do wysokiej temperatury jest następnie schładzane, przez co maleje jego energia. Przeprowadzając w odpowiedni sposób proces

schładzania, można uzyskać sta odpowiadający minimum energii. W zależności od przebiegu procesu schładzania uzyskać można lokalne lub globalne minimum energii. Globalne minimum odpowiada strukturze krystalicznej ciała.

Algorytm symulowanego wyżarzania jest iteracyjny. W każdym kroku wyznaczana jest energia ΔE układu po wprowadzeniu losowego zaburzenia. Jeśli całkowita energia zmniejsza się, zaburzenie jest akceptowane, a powstały stan jest wyjściem dla następnej iteracji. W przypadku zwiększenia energii przez zaburzenie, powstały stan akceptuje się z prawdopodobieństwem $P(\Delta E)$ równym:

$$P(\Delta E) = \exp\left(-\frac{\Delta E}{T}\right), \quad (4.3)$$

gdzie:

T – temperatura wyrażona w jednostkach energii.

Przed zastosowaniem algorytmu należy określić przestrzeń operowania algorytmu, funkcję kosztów, mechanizm wprowadzania zaburzeń, warunek równowagi układu w danej temperaturze, temperaturę początkową, sposób obniżania temperatury i warunek zatrzymania obliczeń. Jeśli proces "schładzania" przeprowadzany jest zbyt szybko, istnieje możliwość utknięcia w minimum lokalnym. Z kolei zbyt wolne przeprowadzanie "schładzania" prowadzi do znacznego wydłużenia czasu obliczeń.

Algorytm symulowanego wyżarzania zastosowano w takich zagadnieniach związanych z systemami elektroenergetycznymi, jak: dobór optymalnej konfiguracji sieci, planowanie rozwoju sieci elektroenergetycznych, dobór baterii kondensatorów.

4.7. Podsumowanie

Dzięki rozwojowi technik zbierania, przechowywania i przesyłania i przetwarzania danych o systemie elektroenergetycznym, możliwe jest coraz lepsze poznanie szeregu problemów. W celu ich rozwiązania opracowuje stosuje się coraz nowsze i doskonalsze techniki przetwarzania informacji, w tym techniki sztucznej inteligencji.

Ilość zastosowań i badań dotyczących zastosowania sztucznych sieci neuronowych zwiększa się bardzo szybko. Szczególnie Ciągłe ulepszana technologia realizacji układów elektronicznych spełniających funkcje sieci neuronowej przyczyniać się będzie do wzrostu liczby zastosowań praktycznych.

Systemy ekspertowe są jedną z technik, które znalazły szerokie zastosowanie w elektroenergetyce. Stosuje się je w rozwiązywaniu problemów, dla których nie ma ściśle sformalizowanych procedur postępowania, gdzie decyzje podejmuje się na podstawie analizy dużej liczby danych. Posiadają możliwość wyjaśniania wyników działania oraz operowania wiedzą niepewną. Integracja systemów ekspertowych przeznaczonych do realizacji zadań w wąskich dziedzinach pozwala na efektywniejsze wykorzystanie zasobów obliczeniowych i danych dla problemów związanych ze sterowaniem, monitorowaniem złożonych systemów elektroenergetycznych.

Algorytmy genetyczne, dzięki swoim właściwościom są stosowane do rozwiązywania zagadnień optymalizacyjnych, w których nie mogą być zastosowane konwencjonalne metody. Stosuje się je w przypadkach problemów wielowymiarowych (o dużej liczbie zmiennych), gdy nieznany jest analityczny algorytm rozwiązania zadania optymalizacji oraz w tzw. problemach NP-zupełnych. Algorytmy genetyczne wymagają dużej mocy obliczeniowej, jednak są łatwe do implementacji we współbieżnych systemach obliczeniowych co wpływa na znaczne skrócenie czasu obliczeń. Często wykorzystuje się w połączeniu z klasycznymi metodami optymalizacji, np. stosowanie metody iteracyjnych dla nowej populacji w celu znalezienia lokalnego optimum.

Algorytm symulowanego wyżarzania pozwala w specyficznych warunkach na osiągnięcie optimum globalnego. Stosowany jest do rozwiązywania problemów wielowymiarowych oraz gdzie występuje szereg minimów lokalnych. Pewną wadą jest zwykle długi czas obliczeń i możliwość utknięcia w minimum lokalnym przy nieodpowiednio dobranych parametrach (np. zbyt szybkie „schładzanie”). Podobnie, jak algorytmy genetyczne może być wykorzystywany dla przypadków, gdy klasyczne metody optymalizacji nie dają zadowalających wyników.

Duże perspektywy rozwojowe stoją przed systemami hybrydowymi, integrującymi różne techniki sztucznej inteligencji a także technik klasyczne w celu efektywniejszego wykorzystania ich własności. Wiele badań dotyczy wykorzystania systemów hybrydowych: połączenia sieci neuronowych z logiką rozmytą, rozmytych systemów ekspertowych, uczących się systemów ekspertowych pozyskujących wiedzę z wykorzystaniem sieci neuronowych.


Zastosowanie technik sztucznej inteligencji w wielu zagadnieniach nie daje wyników lepszych od metod klasycznych. Liczne badania pokazują, że stosowanie technik sztucznej inteligencji przy jednoczesnym wykorzystaniu w bardzo ograniczonym zakresie wiedzy na temat rozpatrywanych zagadnień, nie prowadzi do efektywnych, lepszych od klasycznych, rozwiązań. Stały rozwój technik sztucznej inteligencji, ich hybrydyzacja, przy jednoczesnym

wykorzystaniu w szerszym zakresie wiedzy o problemach, może przyczynić się do znacznie bardziej efektywnego wykorzystania możliwości tkwiących w tych technikach do rozwiązywania różnorodnych problemów z zakresu elektroenergetyki.

5. Sztuczne sieci neuronowe – specyficzne problemy

5.1. Wprowadzenie

Podstawowe informacje dotyczące sztucznych sieci neuronowych zostały przedstawione w rozdz. 4.2. Problemy dotyczące sztucznych sieci neuronowych są omówione na przykładzie najczęściej wykorzystywanej architektury – wielowarstwowej, jednokierunkowej sieci neuronowej ze szczególnym uwzględnieniem możliwości ich zastosowania do problemu klasyfikacji.



Rys. 5.1. Architektura jednokierunkowej, wielowarstwowej sztucznej sieci neuronowej

Schemat wielowarstwowego perceptronu przedstawiono na rys. 5.1 Na warstwę wejściową sieci podawany jest wektor wejściowy $\mathbf{x} = [x_1, x_2, \dots, x_n]$. Każdy z elementów warstwy wejściowej jest połączony z każdym neuronem warstwy ukrytej. Połączenia wagowe posiadają wagi w_{ij} . Neuron j warstwy ukrytej realizuje operację ważonego sumowania wartości wejściowych i przetwarzania jej przez blok nieliniowej funkcji aktywacji F :

$$y_j = F\left(\sum_{i=1}^n w_{ij} x_i + w_j\right) \tag{5.1}$$

gdzie:

w_j – wartość stała (*bias*).


Funkcją aktywacji F , jest najczęściej funkcja sigmoidalna unipolarna, w postaci:

$$f(x) = \frac{1}{1 + e^{-ax}} \quad (5.2)$$

lub bipolarna (tangens hiperboliczny):

$$f(x) = \tanh(ax). \quad (5.3)$$

Przebieg funkcji sigmoidalnej unipolarnej dla różnych wartości współczynnika a przedstawia rys. 5.2. Użycie tej funkcji powoduje ograniczenie wartości wyjściowych do zakresu od 0 do 1 dla funkcji unipolarnej lub od -1 do 1 dla funkcji bipolarnej. Jest to własność szczególnie użyteczna w zagadnieniach klasyfikacji. Także dzięki temu wagi sieci neuronowej będą także przyjmować ograniczone wartości.



Rys. 5. 2. Przebieg unipolarnej funkcji sigmoidalnej dla różnych wartości współczynnika a :
a) unipolarnej, b) bipolarnej.

Sztuczna sieć neuronowa dokonuje nieliniowego odwzorowania danych wejściowych X w dane wyjściowe Y :

$$Y = f(X; \mathbf{w}, \mathbf{A}), \quad (5.4)$$

gdzie:

$\mathbf{w}$ – wagi,

$\mathbf{A}$ – architektura sieci neuronowej.

Celem uczenia sieci neuronowej jest uzyskanie pożądanej wartości na wyjściach sieci, gdy na wejściach aktualnie znajdują się określone wartości, poprzez odpowiednią modyfikację współczynników wagowych. Konieczne jest więc dysponowanie zbiorem uczącym wejściowym i skojarzonym z nim zbiorem wyjściowym, zawierającym pożądane wartości. Do reprezentacji danych wejściowych i wyjściowych stosuje się wektory. Każdy wektor wejściowy

posiada więc odpowiadający mu wektor wyjściowy. Ten rodzaj uczenia, tzw. uczenie nadzorowane, jest najczęściej wykorzystywany w praktyce.

Cechą prawidłowego nauczania sieci neuronowej jest nie tyle uzyskanie dokładnego odwzorowania określonego zbioru danych, co stworzenie możliwości uogólniania, dzięki czemu wyuczona sieć neuronowa będzie generować poprawne wyniki także w przypadku danych spoza zbioru użytego do uczenia poprzez interpolację funkcji odwzorowania f . Stworzenie sztucznej sieci neuronowej, która spełniałaby w rezultacie określone zadania, wymaga rozwiązania specyficznych zagadnień i problemów związanych, między innymi, z:

- doбором architektury – określeniem liczby warstw ukrytych oraz liczby neuronów w każdej warstwie,
- doбором funkcji aktywacji neuronów sieci,
- sposobem inicjacji wag początkowych w przed procesem uczenia,
- stworzeniem odpowiednich zbiorów uczących i odpowiednim sposobem uczenia sieci.

5.1. Architektura sieci neuronowej

Złożoność odwzorowania zbioru danych wejściowych w zbiór danych wyjściowych, realizowanego przez sieć neuronową zależy od liczby wag sieci. Liczba neuronów w warstwie wejściowej i wyjściowej jest zwykle określona przez rozmiary wektorów danych. Dlatego liczbę wag sieci określa rozmiar warstwy ukrytej (lub poszczególnych warstw ukrytych, gdy sieć posiada więcej niż jedną warstwę ukrytą).

Klasyfikacja za pomocą sztucznych sieci neuronowych przebiega w dwóch etapach. W pierwszym etapie sieć jest uczona za pomocą zbioru uczącego. Ustalane są wagi połączeń między neuronami. Następnie sieć jest używana do klasyfikacji, ale z nowym zbiorem testowym. W przypadku, gdy występuje duży błąd klasyfikacji, sieć posiada złe własności uogólniające.

W przypadku zbyt małej ilości wag dobieranych w procesie uczenia odwzorowanie jest zbyt proste i sieć nie jest zdolna do wykonania prawidłowego odwzorowania. Sieć o zbyt małej liczbie wag posiada złe własności uogólniające. Z kolei, w przypadku zbyt dużej liczby wag, sieć wykazuje własność nadmiernego dopasowania się do danych uczących, co również wpływa negatywnie na zdolność do uogólniania. Nadmiarowe wagi dopasowują się do nieistotnych z punktu widzenia problemu subtelności zbioru uczącego i traktują je tym samym jako istotne cechy.

Istnieje wiele metod, które mają na celu określenie optymalnej liczby wag dla danej sieci uczonej przeznaczonej do pewnego problemu. Jednak najczęściej stosuje się metodę prób i błędów polegającą na uczeniu szeregu sieci o różnej liczbie wag i wyborze sieci najlepiej spełniającej określone zadania. Zwykle jest to sieć o najmniejszej liczbie neuronów ukrytych, dająca jednocześnie najmniejszy poziom błędu klasyfikacji przeprowadzonych na, niezależnym od zbioru uczącego, zbiorze testowym. Oprócz tego prostsze i mniej czasochłonne jest uczenie sieci o małej liczbie wag.

5.2. Funkcja aktywacji

W sieci jednokierunkowej, wielowarstwowej uczonej za pomocą algorytmu propagacji wstecznej, teoretycznie może być użyta dowolna funkcja aktywacji posiadająca pochodną. W pewnych przypadkach szczególnych możliwy jest dobór funkcji aktywacji na podstawie cech danych, np. dane posiadają rozkład normalny o określonej wartości średniej i wariancji. Często jednak w praktyce nie dysponuje się tego typu informacjami. Dobór funkcji musi opierać się o szereg warunków, aby sieć neuronowa mogła spełniać swoje zadania. Wśród tych warunków wymienić można:

- nieliniowość,
- minimalna i maksymalna wartość, co pozwoli na uzyskanie ograniczonych wartości wag i wartości na wyjściu sieci,
- różniczkowalność – dzięki temu możliwe jest zastosowanie algorytmu wstecznej propagacji błędów,

Użyteczne, ale nie konieczne cechy to liniowość (przybliżona) dla małych wartości wejściowych oraz monotoniczność (jednakowy znak pochodnej).

Wszystkie wymienione cechy posiada funkcja sigmoidalna, unipolarna lub bipolarna. Jest też najczęściej wykorzystywana w praktyce.

5.3. Inicjacja wag

W przypadku utknięcia w czasie uczenia w minimum lokalnym, tj. w przypadku gdy błąd uczenia nie zmniejsza się lub nawet zwiększa swoją wartość, można rozpocząć uczenie sieci od nowa zmieniając wartości początkowe wag. Ich dobór przeprowadza się w sposób losowy. Wartości początkowe mają istotne znaczenie dla dalszego przebiegu procesu uczenia.

Zbyt duże wartości wag powodują, że osiągnięcie nasycenia przez sigmoidalne funkcje aktywacji. Jeśli wartości wag będą zbyt małe, wagi będą zbiegać do wartości zerowych lub proces uczenia będzie przebiegał bardzo powoli. Jedną z reguł określającą zakres wartości wag początkowych jest reguła dla wag:

- między warstwą wejściową a ukrytą:

$$-\frac{1}{\sqrt{m}} < w_{ji} < \frac{1}{\sqrt{m}}, \quad (5.5)$$

gdzie:

m – liczba wejść,

- między warstwą ukrytą a wyjściową:

$$-\frac{1}{\sqrt{n_H}} < w_{nj} < \frac{1}{\sqrt{n_H}}, \quad (5.6)$$

gdzie:

n_H – liczba neuronów w warstwie ukrytej.

5.4. Zbiory uczące i uczenie sieci neuronowych

Podstawowym algorytmem uczenia nadzorowanego dla jednokierunkowych, wielowarstwowych sieci neuronowych jest algorytm wstecznej propagacji błędów (*Back Propagation Algorithm*) [36], [26], [59]. Proces uczenia sieci neuronowej polega na doborze wag w połączeń między neuronami w taki sposób, aby zminimalizować funkcję błędu $E(\mathbf{w})$, którą dla algorytmu wstecznej propagacji zdefiniowano jako sumę kwadratów błędów uczenia:

$$E(\mathbf{w}) = \frac{1}{2} \sum_{i=1}^m (y_i - d_i)^2, \quad (5.7)$$

gdzie:

y_i – aktualna wartość na wyjściu,

d_i – oczekiwana wartość na wyjściu, m – liczba wyjść.

Uaktualnianie wag może odbywać się zarówno po prezentacji pojedynczej próbki uczącej, jak i po prezentacji wszystkich próbek uczących.

Najczęściej wykorzystywanymi metodami minimalizacji funkcji błędu są metody gradientowe, w których dobór wag przebiega iteracyjnie, zgodnie z zależnością:


$$\mathbf{w}(k+1) = \mathbf{w}(k) + \eta \nabla E(\mathbf{w}), \quad (5.8)$$

gdzie:

k – numer kolejnej iteracji.

Dobór wag w poszczególnych warstwach sieci wymaga odpowiedniego sposobu postępowania, polegającego na przesyłaniu wstecz błędów z warstwy wyjściowej, aby określić zmiany wag w poprzednich warstwach.

Opis algorytmu dotyczy sieci neuronowej jednokierunkowej, z warstwą wejściową liczącą n_0 neuronów, z jedną warstwą ukrytą liczącą n_1 neuronów oraz warstwą wyjściową o n_2 neuronach. Opisany przypadek można uogólnić na sieci o większej liczbie warstw ukrytych.



Rys. 5.3. Schemat sieci neuronowej trójwarstwowej z funkcją aktywacji F .

Przy zastosowaniu oznaczeń jak na rys.5.3 modyfikacja wag odbywa się zgodnie z zależnością:

$$\Delta w_{ji}^{(2)} = -\eta \frac{\partial E}{\partial w_{ji}^{(2)}} = -\eta \frac{\partial E}{\partial u_j^{(2)}} \frac{\partial u_j^{(2)}}{\partial w_{ji}^{(2)}}, \quad (5.9)$$

gdzie:

η – współczynnik uczenia,

$$u_j^{(2)} = \sum_{i=1}^{n_1} w_{ji}^{(2)} o_i^{(1)}.$$

Gradient funkcji błędu wynosi:

$$\frac{\partial E}{\partial w_{ji}^{(2)}} = (y_j - d_j) \frac{\partial F}{\partial u_j^{(2)}} o_i^{(1)}. \quad (5.10)$$

Podstawiając

$$\delta_j^{(2)} = (y_j - d_j) \frac{\partial F}{\partial u_j^{(2)}} \quad (5.11)$$

aktualizacja wag w warstwie wyjściowej:

$$w_{ji}^{(2)}(k) = w_{ji}^{(2)}(k-1) + \Delta w_{ji}^{(2)} \quad (5.12)$$

wynosi:

$$\Delta w_{ji}^{(2)} = -\eta \delta_j^{(2)} o_i^{(1)}. \quad (5.13)$$

Dla neuronów w warstwach ukrytych aktualizacja wag przyjmuje postać:

$$\Delta w_{ji}^{(1)} = -\eta \delta_j^{(1)} x_i, \quad (5.14)$$

gdzie:

$$\delta_j^{(1)} = \frac{\partial F}{\partial u_j^{(1)}} \sum_{i=1}^{n_2} \delta_i^{(2)} w_{ij}^{(2)}. \quad (5.15)$$

Algorytm wstecznej propagacji składa się z następujących etapów:

- inicjalizacja wag małymi wartościami losowymi,
- wyznaczenie wartości sygnałów wyjściowych neuronów w warstwach ukrytych warstwie i wyjściowej,
- obliczenie wartości błędów dla warstwy wyjściowej $\delta_j^{(2)}$,
- propagacja wsteczna błędu wyjściowego do poszczególnych neuronów warstwy ukrytej, poprzez wyznaczenie $\delta_j^{(1)}$,
- aktualizacja wag kolejno między warstwą wyjściową i ukrytą i kierunku warstwy wyjściowej.

Współczynnik uczenia służy do zwiększenia szybkości działania algorytmu, jednak jego nieodpowiednia (zbyt duża wartość) może doprowadzić do rozbieżności algorytmu. Innym sposobem przyspieszania algorytmu propagacji wstecznej jest wprowadzenie dodatkowego członu tzw. momentum, który do aktualizowanych wag dodaje część ich przyrostu z poprzedniego kroku:

$$\Delta w(k+1) = -\eta \frac{\partial E}{\partial w} + \alpha \Delta w(k), \quad (5.16)$$

gdzie:

α – stała określająca wpływ poprzedniej zmiany wag na aktualną; przyjmuje wartości z przedziału $0 < \alpha < 1$.

Algorytm wstecznej propagacji nie zawsze pozwala na znalezienie globalnego minimum funkcji błędu uczenia (jest to cecha algorytmów wykorzystujących metodę największe-

go spadku). Możliwy do zaakceptowania jest przypadek osiągnięcia optimum lokalnego przy jednoczesnym uzyskaniu wymaganej dokładności. Zwykle jednak uczenie sieci należy przeprowadzać wielokrotnie dla zmienionych parametrów uczenia (współczynnika uczenia, momentum), różnych wartości początkowych wag, liczby neuronów w warstwie ukrytej.

6. Nowa metoda weryfikacji topologii systemu elektroenergetycznego

6.1. Charakterystyka podejścia

Generalnym założeniem przyjmowanego podejścia jest, że gdy model topologii systemu elektroenergetycznego jest poprawny, to dla poprawnych danych pomiarowych są spełnione wszystkie związki, wynikające z praw Ohma oraz Kirchhoffa, obowiązujące dla tego systemu. Wystąpienie błędu topologii daje w rezultacie niespełnienie pewnych związków pomiędzy mierzonymi wielkościami [8].

W rzeczywistości, gdy dane pomiarowe obarczone są błędami, również te błędy - oprócz błędów topologii - wpływają na spełnienie albo niespełnienie rozpatrywanych związków. Im więcej informacji, zawartej w danych pomiarowych oraz związkach pomiędzy mierzonymi wielkościami będzie brane pod uwagę, tj. im więcej danych pomiarowych oraz związków będzie uwzględnionych, tym korzystniejszy powinien być otrzymany wynik weryfikacji.

Nawet dla niewielkiego fragmentu systemu elektroenergetycznego analiza obowiązujących dla niego związków w celu stwierdzenia istnienia błędów topologii, gdy dane pomiarowe obarczone są błędami, nie należy do zadań prostych. Z uwagi na to, że weryfikacja topologii może być traktowana jako problem klasyfikacji wzorców, można - jak to stwierdzano wielokrotnie w literaturze - zastosować do wspomnianej analizy sztuczne sieci neuronowe. W opisywanym podejściu do weryfikacji topologii uwzględniono doświadczenia badaczy, zajmujących się wykorzystywaniem sztucznych sieci neuronowych, które wskazują na to, że można zwiększyć efektywność stosowania sztucznych sieci neuronowych poprzez jednoczesną maksymalizację wykorzystania wiedzy o obiekcie.

Dążąc do tej maksymalizacji wykorzystania wiedzy o obiekcie, przewidziano uwzględnienie nie tylko bilansów mocy czynnych (jak to jest robione w metodach opisanych w literaturze), ale także i bilansów mocy biernych w węzłach systemu elektroenergetycznego oraz związków pomiędzy przepływami mocy czynnych, biernych i poziomami napięć dla poszczególnych gałęzi.

Mówiąc o związkach pomiędzy przepływami mocy czynnych, biernych i poziomami napięć dla gałęzi bierze się tu pod uwagę związki, które obowiązują dla pracującej gałęzi, tj. dla gałęzi włączonej na obu końcach. W dalszym ciągu pracy nawiązując do związków po-

między przepływami mocy czynnych, biernych i poziomami napięć dla gałęzi, tylko takie związki są rozpatrywane.

Należy zwrócić uwagę na to, że w procesie weryfikacji topologii dla wielkości wyróżnianych dla niewłaściwie pominiętego w modelu systemu elektroenergetycznego elementu nie można rozpatrywać spełnienia związków, które obowiązują dla włączonego (inaczej mówiąc pracującego) elementu, w zbiorze danych pomiarowych tych wielkości. Stanowi to istotną trudność w uwzględnieniu związków pomiędzy przepływami mocy czynnych, biernych i poziomami napięć dla gałęzi, która błędnie nie została uwzględniona w modelu. Związki te winny być bowiem rozpatrywane także wtedy, gdy gałąź nie jest uwzględniona w modelu podczas, gdy w rzeczywistości jest włączona. Aby zapewnić rozpatrywanie takich związków w każdej sytuacji, przyjęto, że będą one badane w zbiorze niezbilansowań węzłów końcowych rozpatrywanej gałęzi. U podstaw takiego postępowania leży spostrzeżenie, że wtedy gdy nie jest uwzględniona gałąź w modelu, to niezbilansowania węzłów końcowych gałęzi będą równe z dokładnością do znaków przepływowi mocy w gałęzi przy tych węzłach końcowych, o ile spełnione są założenia:

- wszystkie inne gałęzie dochodzące do węzłów końcowych rozpatrywanej gałęzi są poprawnie uwzględnione w modelu,
- nie są rozpatrywane błędy obarczające dane pomiarowe.

Oczywistą jest rzeczą, że po odpowiednim uwzględnieniu znaków niezbilansowań w węzłach końcowych gałęzi, po wstawieniu tych niezbilansowań do związków dla gałęzi, która w rzeczywistości jest włączona, otrzyma się spełnienie tychże związków. Nie zawsze związki dla gałęzi będą spełnione, gdy wymienione wcześniej założenia nie będą miały miejsca.

Do podanych uwag należy dodać także tę, że z punktu widzenia dowolnej, włączonej w rzeczywistości gałęzi, poprawnie uwzględnionej w modelu systemu elektroenergetycznego, niezbilansowania węzłów końcowych -ogólnie rzecz biorąc - nie są równe z dokładnością do znaków przepływowi mocy w gałęzi przy tych węzłach końcowych. Oznacza to, że do związków dla branych obecnie pod uwagę gałęzi będą wstawiane niewłaściwe dane. W przypadku idealnym omawiane związki nie będą więc spełnione.

Z przeprowadzonych rozważań należy wyciągnąć wniosek, że gdy tylko jedna z włączonych w rzeczywistości gałęzi jest niewłaściwie uwzględniona w modelu systemu elektroenergetycznego, to dla tej gałęzi spełnione są związki pomiędzy przepływami mocy czynnych, biernych i poziomami napięć na końcach pracującej gałęzi w zbiorze odpowiednio rozpatrywanych niezbilansowań węzłów końcowych gałęzi, podczas gdy dla pozostałych ga-

łęzi wspomniane związki nie są spełnione. Powstaje więc bardzo charakterystyczna sytuacja dla niewłaściwego uwzględnienia gałęzi w modelu systemu elektroenergetycznego, która w rzeczywistości jest włączona.

Badanie spełnienia związków pomiędzy przepływami mocy czynnych, biernych i poziomami napięć na końcach gałęzi w zbiorze odpowiednio rozpatrywanych niezbilansowań węzłów końcowych gałęzi zostało uwzględnione przy opracowywaniu nowej metody weryfikacji topologii. Konsekwencje takiego badania bardziej szczegółowo omówione zostały dalej.

Podsumowując i jednocześnie uzupełniając przedstawioną charakterystykę nowego podejścia do weryfikacji topologii systemu elektroenergetycznego, można podać następującą przyjmowaną dla niego listę podstawowych założeń:

1. Brane są pod uwagę dane pomiarowe przepływów mocy czynnej, biernej oraz poziomów napięć.
2. Uwzględniana jest wiedza o systemie elektroenergetycznym zawarta w związkach pomiędzy przepływami mocy czynnych, biernych i poziomami napięć, rozpatrywanych dla węzłów oraz gałęzi systemu elektroenergetycznego, które wynikają z praw Kirchhoffa oraz Ohma.
3. Wykorzystywanych jest wielu sztucznych sieci neuronowych, z których każda skojarzona jest z jednym węzłem systemu elektroenergetycznego.
4. Sztuczna sieć neuronowa skojarzona z danym węzłem systemu elektroenergetycznego jest wykorzystywana do klasyfikacji poprawności uwzględnienia gałęzi dochodzących do tego węzła.

6.2. Podstawy teoretyczne

6.2.1. Brane pod uwagę związki

Przy opracowywaniu nowej metody uwzględniono:

- bilanse mocy czynnych i biernych w węzłach systemu elektroenergetycznego

$$\sum_{i \in I_k} P_i = 0, \quad (6.1)$$


$$\sum_{i \in I_k} Q_i = 0, \quad (6.2)$$

gdzie:

P_i – przepływ mocy czynnej w i -tej gałęzi,

Q_i – przepływ mocy biernej w i -tej gałęzi,

I_k – zbiór gałęzi incydentnych z węzłem k ,



Rys. 6. 1. Model gałęzi typu Π . Oznaczenia: P_1, P_2 – przepływy mocy czynnej odpowiednio na początku i na końcu gałęzi; Q_1, Q_2 – przepływy mocy biernej odpowiednio na początku i na końcu gałęzi; U_1, U_2 – poziomy napięcie; R, X_L, B_C – parametry modelu Π .

- związki pomiędzy przepływami mocy czynnych, biernych i poziomami napięć na końcach gałęzi, przy założeniu, że gałąź jest modelowana z wykorzystaniem czwórnika typu Π (rys. 6. 1):

$$P_1 + P_2 + R \frac{P_1^2 + \left(Q_1 - \frac{B_C}{2} U_1^2\right)^2}{U_1^2} = 0, \quad (6.3)$$

$$P_1 + P_2 + R \frac{P_2^2 + \left(Q_2 - \frac{B_C}{2} U_2^2\right)^2}{U_2^2} = 0, \quad (6.4)$$

$$Q_1 + Q_2 + X_L \frac{P_1^2 + \left(Q_1 - \frac{B_C}{2} U_1^2\right)^2}{U_1^2} - \frac{B_C}{2} (U_1^2 + U_2^2) = 0, \quad (6.5)$$

$$Q_1 + Q_2 + X_L \frac{P_2^2 + \left(Q_2 - \frac{B_C}{2} U_2^2\right)^2}{U_2^2} - \frac{B_C}{2} (U_1^2 + U_2^2) = 0. \quad (6.6)$$

Dla potrzeb nowej metody wprowadzono pojęcie wskaźników niezbilansowania dla węzłów oraz gałęzi. Przy definiowaniu tych wskaźników uwzględniono związki (6.1) - (6.6).

6.2.2. Definicje wskaźników niezbilansowania dla węzłów

Wskaźniki niezbilansowania dla węzłów definiowane są następująco:

- wskaźnik niezbilansowania mocy czynnej dla k -tego węzła

$$W_{P_k} = \sum_{i \in I_k} P_i, \quad (6.7)$$

- wskaźnik niezbilansowania mocy biernej dla k -tego węzła

$$W_{Q_k} = \sum_{i \in I_k} Q_i. \quad (6.8)$$

Wskaźniki W_{P_k} oraz W_{Q_k} stanowią lewe strony związków odpowiednio 6.1, 6.2.

6.2.3. Definicje wskaźników niezbilansowania dla gałęzi

Wskaźniki niezbilansowania dla gałęzi definiowane są następująco:

- wskaźniki niezbilansowania mocy czynnej dla j -tej gałęzi

$$W_{LjP1} = -W_{P1j} - W_{P2j} + R \frac{W_{P1j}^2 + \left(W_{Q1j} + \frac{B_C}{2} U_{1j}^2\right)^2}{U_{1j}^2}, \quad (6.9)$$

$$W_{LjP2} = -W_{P1j} - W_{P2j} + R \frac{W_{P2j}^2 + \left(W_{Q2j} + \frac{B_C}{2} U_{2j}^2\right)^2}{U_{2j}^2}, \quad (6.10)$$

- wskaźniki niezbilansowania mocy biernej dla j -tej gałęzi

$$W_{LjQ1} = -W_{Q1j} - W_{Q2j} + X_L \frac{W_{P1j}^2 + \left(W_{Q1j} + \frac{B_C}{2} U_{1j}^2\right)^2}{U_{1j}^2} - \frac{B_C}{2} (U_{1j}^2 + U_{2j}^2), \quad (6.11)$$

$$W_{LjQ2} = -W_{Q1j} - W_{Q2j} + X_L \frac{W_{P2j}^2 + \left(W_{Q2j} + \frac{B_C}{2} U_{2j}^2\right)^2}{U_{2j}^2} - \frac{B_C}{2} (U_{1j}^2 + U_{2j}^2), \quad (6.12)$$

gdzie:

U_{1j}, U_{2j} - napięcia odpowiednio w węzłach początkowym i końcowym j -tej gałęzi.

Wskaźniki niezbilansowania dla gałęzi, określone wzorami (6.9) - (6.12), stanowią lewe strony związków odpowiednio (6.3) - (6.6) po uwzględnieniu:

$$P_1 = -W_{P1j}, \quad (6.13)$$

$$P_2 = -W_{P2j}, \quad (6.14)$$

$$Q_1 = -W_{Q1j}, \quad (6.15)$$

$$Q_2 = -W_{Q2j}, \quad (6.16)$$

gdzie:

W_{P1j}, W_{P2j} - wskaźniki niezbilansowania mocy czynnej dla węzłów odpowiednio początkowego i końcowego gałęzi j ,

W_{Q1j}, W_{Q2j} - wskaźniki niezbilansowania mocy biernej dla węzłów odpowiednio początkowego i końcowego gałęzi j .

6.2.4. Analiza wskaźników niezbilansowania dla węzłów w przypadku braku błędów topologii

Przypadek idealny

W tym przypadku dla $i \in I_k$

$$z_{Pi} = P_i, \quad (6.17)$$

$$z_{Qi} = Q_i, \quad (6.18)$$

gdzie:

z_{Pi}, z_{Qi} - dane pomiarowe odpowiednio przepływu mocy czynnej P_i oraz przepływu mocy biernej Q_i ,

oraz bilanse mocy czynnych i biernych w węźle są spełnione, czyli mają miejsce (6.1), (6.2). Oznacza to, że:

$$W_{Pk} = 0, \quad (6.19)$$

$$W_{Qk} = 0. \quad (6.20)$$

Przypadek rzeczywisty

W przypadku rzeczywistym należy przyjąć, że:

$$z_{Pi} = P_i + e_{Pi}, \quad (6.21)$$

$$z_{Qi} = Q_i + e_{Qi}, \quad (6.22)$$

gdzie:

e_{Pi} , e_{Qi} - błędy obarczające dane pomiarowe odpowiednio przepływu mocy czynnej P_i oraz przepływu mocy biernej Q_i ,

i w efekcie wobec (6.1), (6.2) zachodzi

$$W_{Pk} = \sum_{i \in I_k} e_{Pi}, \quad (6.23)$$

$$W_{Qk} = \sum_{i \in I_k} e_{Qi}. \quad (6.24)$$

Wzory (6.23), (6.24) pokazują, że wskaźniki niezbilansowania mocy czynnej oraz biernej w węźle niekoniecznie muszą być obecnie równe zero.

6.2.5. Analiza wskaźników niezbilansowania dla węzła w przypadku nieuwzględnienia w modelu rzeczywistości włączonej gałęzi

W tym przypadku przy obliczaniu wskaźników niezbilansowania dla węzła nie uwzględnia się przepływu mocy czynnej oraz biernej w gałęzi j , która nie jest uwzględniona w modelu. Wskaźniki niezbilansowania dla węzła będą się różniły od tych, wyznaczonych dla przypadku opisanego w 6.2.4., o wartości odpowiednich danych pomiarowych o przepływach w gałęzi j .

Przypadek idealny

$$W_{Pk} = -P_j, \quad (6.25)$$

$$W_{Qk} = -Q_j. \quad (6.26)$$

Przypadek rzeczywisty

$$W_{Pk} = \sum_{i \in I_k} z_{Pi} - z_{Pj} = \sum_{\substack{i \in I_k \\ i \neq j}} z_{Pi} = \sum_{i \in I_k} e_{Pi} - z_{Pj} = \sum_{\substack{i \in I_k \\ i \neq j}} e_{Pi} - P_j, \quad (6.27)$$

$$W_{Qk} = \sum_{i \in I_k} z_{Qi} - z_{Qj} = \sum_{\substack{i \in I_k \\ i \neq j}} z_{Qi} = \sum_{i \in I_k} e_{Qi} - z_{Qj} = \sum_{\substack{i \in I_k \\ i \neq j}} e_{Qi} - Q_j. \quad (6.28)$$

6.2.6. Analiza wskaźników niezbilansowania dla węzłów w przypadku uwzględnienia w modelu rzeczywistości wyłączzonej gałęzi

Dla gałęzi j , która w modelu jest uwzględniona, ale w rzeczywistości jest wyłączona, przepływy na jej końcach są równe zeru. Z tego faktu wynika, że w przypadku idealnym wskaźniki niezbilansowania dla węzła nie będą się różniły od tych, wyznaczonych dla przypadku opisanego w 6.2.4., w przypadku rzeczywistym będą się co najwyżej różniły od wskaźników, wyznaczonych dla przypadku z 6.2.4., o wartość odpowiednich błędów.

Przypadek idealny

$$W_{Pk} = 0, \quad (6.29)$$

$$W_{Qk} = 0. \quad (6.30)$$

Przypadek rzeczywisty

$$W_{Pk} = \sum_{i \in I_k} e_{Pi} + e_{Pj}, \quad (6.31)$$

$$W_{Qk} = \sum_{i \in I_k} e_{Qi} + e_{Qj}. \quad (6.32)$$

6.2.7. Analiza wskaźników niezbilansowania dla gałęzi w przypadku braku błędów topologii**Przypadek idealny**

W tym przypadku obowiązują zależności (6.19), (6.20) i w związku z tym:

$$W_{LjP1} = 0.25 R B_C^2 U_{1j}^2, \quad (6.33)$$

$$W_{LjP2} = 0.25 R B_C^2 U_{2j}^2, \quad (6.34)$$

$$W_{LjQ1} = 0.25 X_L B_C^2 U_{1j}^2 - 0.5 B_C (U_{1j}^2 + U_{2j}^2), \quad (6.35)$$

$$W_{LjQ2} = 0.25 X_L B_C^2 U_{2j}^2 - 0.5 B_C (U_{1j}^2 + U_{2j}^2), \quad (6.36)$$

W przypadku braku błędów topologii wskaźniki niezbilansowania dla gałęzi nie są równe zero. Chcąc dysponować zerowymi wartościami tych wskaźników dla omawianego przypadku błędów topologii należy dokonać korekty wskaźników niezbilansowania o wartości podane wyżej. Warunkowe przeprowadzenie takiej korekty wtedy, gdy wskaźniki niezbilansowania dla węzłów końcowych gałęzi są równe zero, pozwala uniknąć niekorzystnego jej wpływu w innych przypadkach występowania/niewystępowania błędów.

Przypadek rzeczywisty

W tym przypadku obowiązują zależności (6.19), (6.20) i w związku z tym:

$$W_{LjP1} = - \sum_{i \in I_{1j}} e_{Pi} - \sum_{i \in I_{2j}} e_{Pi} + R \frac{\left(\sum_{i \in I_{1j}} e_{Pi} \right)^2 + \left(\sum_{i \in I_{1j}} e_{Qi} + \frac{B_C}{2} z_{1j}^2 \right)^2}{z_{1j}^2}, \quad (6.37)$$

$$W_{LjP2} = - \sum_{i \in I_{1j}} e_{Pi} - \sum_{i \in I_{2j}} e_{Pi} + R \frac{\left(\sum_{i \in I_{2j}} e_{Pi} \right)^2 + \left(\sum_{i \in I_{2j}} e_{Qi} + \frac{B_C}{2} z_{2j}^2 \right)^2}{z_{2j}^2}, \quad (6.38)$$

$$W_{LjQ1} = - \sum_{i \in I_{1j}} e_{Qi} - \sum_{i \in I_{2j}} e_{Qi} + X_L \frac{\left(\sum_{i \in I_{1j}} e_{Pi} \right)^2 + \left(\sum_{i \in I_{1j}} e_{Qi} + \frac{B_C}{2} z_{1j}^2 \right)^2}{z_{1j}^2} - \frac{B_C}{2} (z_{1j}^2 + z_{2j}^2), \quad (6.39)$$

$$W_{LjQ2} = - \sum_{i \in I_{1j}} e_{Qi} - \sum_{i \in I_{2j}} e_{Qi} + X_L \frac{\left(\sum_{i \in I_{2j}} e_{Pi} \right)^2 + \left(\sum_{i \in I_{2j}} e_{Qi} + \frac{B_C}{2} z_{2j}^2 \right)^2}{z_{2j}^2} - \frac{B_C}{2} (z_{1j}^2 + z_{2j}^2). \quad (6.40)$$

W tym przypadku przeprowadzenie korekty, o której wspomniano wcześniej, powinno mieć miejsce wtedy, gdy wskaźniki niezbilansowania dla węzłów końcowych gałęzi różnią się dostatecznie mało od zera (moduły wskaźników niezbilansowania dla węzłów są mniejsze od odpowiednio wybranych dostatecznie małych wartości).

6.2.8. Analiza wskaźników niezbilansowania dla rzeczywiście włączonej gałęzi w przypadku nieuwzględnienia jej w modelu

Przypadek idealny

W tym przypadku obowiązują zależności (6.25), (6.26) i w związku z tym:

$$W_{LjP1} = 0, \quad (6.41)$$

$$W_{LjP2} = 0, \quad (6.42)$$

$$W_{LjQ1} = 0, \quad (6.43)$$

$$W_{LjQ2} = 0. \quad (6.44)$$

Przypadek rzeczywisty

W tym przypadku obowiązują zależności (6.27), (6.28) i w związku z tym:

$$W_{LjP1} = - \sum_{\substack{i \in I_{1j} \\ i \neq j}} e_{Pi} - \sum_{\substack{i \in I_{2j} \\ i \neq j}} e_{Pi} + \quad (6.45)$$

$$+ R \frac{\left(\sum_{\substack{i \in I_{1j} \\ i \neq j}} z_{Pi} \right)^2 + \left(\sum_{\substack{i \in I_{1j} \\ i \neq j}} z_{Qi} + \frac{B_C}{2} z_{U1j}^2 \right)^2}{z_{U1j}^2} - R \frac{\left(\sum_{\substack{i \in I_{1j} \\ i \neq j}} P_i \right)^2 + \left(\sum_{\substack{i \in I_{1j} \\ i \neq j}} Q_i + \frac{B_C}{2} U_{1j}^2 \right)^2}{U_{1j}^2}$$

$$W_{LjP2} = - \sum_{\substack{i \in I_{1j} \\ i \neq j}} e_{Pi} - \sum_{\substack{i \in I_{2j} \\ i \neq j}} e_{Pi} + \quad (6.46)$$

$$+ R \frac{\left(\sum_{\substack{i \in I_{2j} \\ i \neq j}} z_{Pi} \right)^2 + \left(\sum_{\substack{i \in I_{2j} \\ i \neq j}} z_{Qi} + \frac{B_C}{2} z_{U2j}^2 \right)^2}{z_{U2j}^2} - R \frac{\left(\sum_{\substack{i \in I_{2j} \\ i \neq j}} P_i \right)^2 + \left(\sum_{\substack{i \in I_{2j} \\ i \neq j}} Q_i + \frac{B_C}{2} U_{2j}^2 \right)^2}{U_{2j}^2}$$

$$W_{LjQ1} = - \sum_{\substack{i \in I_{1j} \\ i \neq j}} e_{Qi} - \sum_{\substack{i \in I_{2j} \\ i \neq j}} e_{Qi} +$$

$$+ X_L \frac{\left(\sum_{\substack{i \in I_{1j} \\ i \neq j}} z_{Pi} \right)^2 + \left(\sum_{\substack{i \in I_{1j} \\ i \neq j}} z_{Qi} + \frac{B_C}{2} z_{U1j}^2 \right)^2}{z_{U1j}^2} - X_L \frac{\left(\sum_{\substack{i \in I_{1j} \\ i \neq j}} P_i \right)^2 + \left(\sum_{\substack{i \in I_{1j} \\ i \neq j}} Q_i + \frac{B_C}{2} U_{1j}^2 \right)^2}{U_{1j}^2} \quad (6.47)$$

$$+ \frac{B_C}{2} (z_{U1j}^2 + z_{U2j}^2 - U_{1j}^2 + U_{2j}^2)$$

$$\begin{aligned}
 W_{LjQ2} = & - \sum_{\substack{i \in I_{1j} \\ i \neq j}} e_{Qi} - \sum_{\substack{i \in I_{2j} \\ i \neq j}} e_{Qi} + \\
 & + X_L \frac{\left(\sum_{\substack{i \in I_{2j} \\ i \neq j}} z_{Pi} \right)^2 + \left(\sum_{\substack{i \in I_{2j} \\ i \neq j}} z_{Qi} + \frac{B_C}{2} z_{U_{2j}}^2 \right)^2}{z_{U_{1j}}^2} - X_L \frac{\left(\sum_{\substack{i \in I_{2j} \\ i \neq j}} P_i \right)^2 + \left(\sum_{\substack{i \in I_{2j} \\ i \neq j}} Q_i + \frac{B_C}{2} U_{2j}^2 \right)^2}{U_{2j}^2} \quad (6.48) \\
 & + \frac{B_C}{2} (z_{U_{1j}}^2 + z_{U_{2j}}^2 - U_{1j}^2 + U_{2j}^2).
 \end{aligned}$$

W przypadku rzeczywistym, gdy gałąź rzeczywiście włączona nie jest uwzględniona w modelu, wskaźniki niezbilansowania dla gałęzi różnią się od zera o wartości zależne od błędów obarczających dane pomiarowe.

6.2.9. Analiza wskaźników niezbilansowania dla rzeczywiście wyłączonej gałęzi w przypadku uwzględnienia jej w modelu

Przypadek idealny

W tym przypadku obowiązują zależności (6.29), (6.30) i w związku z tym:

$$W_{LjP1} = 0.25 R B_C^2 U_{1j}^2, \quad (6.49)$$

$$W_{LjP2} = 0.25 R B_C^2 U_{2j}^2, \quad (6.50)$$

$$W_{LjQ1} = 0.25 X_L B_C^2 U_{1j}^2 - 0.5 B_C (U_{1j}^2 + U_{2j}^2), \quad (6.51)$$

$$W_{LjQ2} = 0.25 X_L B_C^2 U_{2j}^2 - 0.5 B_C (U_{1j}^2 + U_{2j}^2). \quad (6.52)$$

Wartości wskaźników niezbilansowania dla tego przypadku są takie same, jak dla przypadku idealnego opisanego w 6.2.7.

Przypadek rzeczywisty

W tym przypadku obowiązują zależności (6.31), (6.32) i w związku z tym:

$$\begin{aligned}
 W_{LjP1} = & -\sum_{i \in I_{1j}} e_{Pi} - \sum_{i \in I_{2j}} e_{Pi} - e_{P1j} - e_{P2j} + \\
 & + R \frac{\left(e_{P1j} + \sum_{i \in I_{1j}} e_{Pi} \right)^2 + \left(e_{Q1j} + \sum_{i \in I_{1j}} e_{Qi} + \frac{B_C}{2} z_{1j}^2 \right)^2}{z_{1j}^2}
 \end{aligned} \tag{6.53}$$

$$\begin{aligned}
 W_{LjP2} = & -\sum_{i \in I_{1j}} e_{Pi} - \sum_{i \in I_{2j}} e_{Pi} - e_{P1j} - e_{P2j} + \\
 & + R \frac{\left(e_{P2j} + \sum_{i \in I_{2j}} e_{Pi} \right)^2 + \left(e_{Q2j} + \sum_{i \in I_{2j}} e_{Qi} + \frac{B_C}{2} z_{2j}^2 \right)^2}{z_{2j}^2}
 \end{aligned} \tag{6.54}$$

$$\begin{aligned}
 W_{LjQ1} = & -\sum_{i \in I_{1j}} e_{Qi} - \sum_{i \in I_{2j}} e_{Qi} - e_{Q1j} - e_{Q2j} \\
 & + X_L \frac{\left(e_{P1j} + \sum_{i \in I_{1j}} e_{Pi} \right)^2 + \left(e_{Q1j} + \sum_{i \in I_{1j}} e_{Qi} + \frac{B_C}{2} z_{1j}^2 \right)^2}{z_{1j}^2} - \frac{B_C}{2} (z_{1j}^2 + z_{2j}^2)
 \end{aligned} \tag{6.55}$$

$$\begin{aligned}
 W_{LjQ2} = & -\sum_{i \in I_{1j}} e_{Qi} - \sum_{i \in I_{2j}} e_{Qi} - e_{Q1j} - e_{Q2j} \\
 & + X_L \frac{\left(e_{P2j} + \sum_{i \in I_{2j}} e_{Pi} \right)^2 + \left(e_{Q2j} + \sum_{i \in I_{2j}} e_{Qi} + \frac{B_C}{2} z_{2j}^2 \right)^2}{z_{2j}^2} - \frac{B_C}{2} (z_{1j}^2 + z_{2j}^2)
 \end{aligned} \tag{6.56}$$

W tym przypadku wartości wskaźników niezbilansowania różnią się od wartości, które te wskaźniki przyjmują w przypadku rzeczywistym opisanym w 6.2.7, z uwagi na występowanie we wzorach (6.53), (6.56) błędów e_{P1j} , e_{P2j} , e_{Q1j} , e_{Q2j} . Nie należy jednak przypuszczać, by wskazane różnice były zbyt duże.

6.2.10. Analiza wskaźników niezbilansowania dla właściwie uwzględnionej w modelu gałęzi incydentnej do węzła, do którego dochodzi gałąź rozpatrzona w rozdz. 6.2.8.

Dla ustalenia uwagi, tutaj jest przyjmowane, że węzeł początkowy rozpatrywanej (j - tej) gałęzi jest tym węzłem, do którego dochodzą tylko gałęzie poprawnie uwzględnione w modelu. Z gałęzią, o której jest mowa w rozdz. 6.2.8., skojarzony jest indeks l .

Przypadek idealny

W tym przypadku obowiązują zależności:

- (6.19), (6.20) dla węzła, do którego dochodzą tylko gałęzie poprawnie uwzględnione w modelu,
- (6.25), (6.26) dla węzła, do którego dochodzi rzeczywiście włączona gałąź nieuwzględniona w modelu,

i w związku z tym:

$$W_{LjP1} = P_{2l} + 0.25R B_C^2 U_{1j}^2, \quad (6.57)$$

$$W_{LjP2} = P_{2l} + 0.25R B_C^2 U_{2j}^2, \quad (6.58)$$

$$W_{LjQ1} = Q_{2l} + 0.25X_L B_C^2 U_{1j}^2 - 0.5 B_C (U_{1j}^2 + U_{2j}^2), \quad (6.59)$$

$$W_{LjQ2} = Q_{2l} + 0.25X_L B_C^2 U_{2j}^2 - 0.5 B_C (U_{1j}^2 + U_{2j}^2). \quad (6.60)$$

Wartości wskaźników niezbilansowania dla tego przypadku różnią się od tych, które mają miejsce w przypadku idealnym opisanym w 6.2.7, o wartości odpowiednich przepływów mocy czynnej albo biernej. Z tego faktu wynika, że moduły wskaźników niezbilansowania mogą przyjmować znaczne wartości, w zależności tego, jakie wartości przyjmują przepływy mocy w gałęzi.

Przypadek rzeczywisty

W tym przypadku obowiązują zależności (6.19), (6.20) i w związku z tym:

$$W_{LjP1} = - \sum_{i \in I_{1j}} e_{Pi} - \sum_{\substack{i \in I_{2j} \\ i \neq l}} e_{Pi} + P_{2l} + R \frac{\left(\sum_{i \in I_{2j}} e_{Pi} \right)^2 + \left(\sum_{i \in I_{1j}} e_{Qi} + \frac{B_C}{2} z_{1j}^2 \right)^2}{z_{1j}^2}, \quad (6.61)$$

$$W_{ljP2} = -\sum_{i \in I_{1j}} e_{pi} - \sum_{\substack{i \in I_{2j} \\ i \neq l}} e_{pi} + P_{2l} +$$

$$+ R \frac{\left(-\sum_{\substack{i \in I_{2j} \\ i \neq l}} e_{pi} + P_{2l} \right)^2 + \left(-\sum_{\substack{i \in I_{2j} \\ i \neq l}} e_{Qi} + Q_{2l} - \frac{B_C}{2} z_{1j}^2 \right)^2}{z_{2j}^2} \quad (6.62)$$

$$W_{ljQ1} = -\sum_{i \in I_{1j}} e_{Qi} - \sum_{\substack{i \in I_{2j} \\ i \neq l}} e_{Qi} + Q_{2l} +$$

$$+ X_L \frac{\left(\sum_{i \in I_{1j}} e_{pi} \right)^2 + \left(\sum_{i \in I_{1j}} e_{Qi} + \frac{B_C}{2} z_{1j}^2 \right)^2}{z_{1j}^2} - \frac{B_C}{2} (z_{1j}^2 + z_{2j}^2) \quad (6.63)$$

$$W_{ljQ2} = -\sum_{i \in I_{1j}} e_{Qi} - \sum_{\substack{i \in I_{2j} \\ i \neq l}} e_{Qi} + Q_{2l} +$$

$$+ X_L \frac{\left(-\sum_{\substack{i \in I_{2j} \\ i \neq l}} e_{pi} + P_{2l} \right)^2 + \left(-\sum_{\substack{i \in I_{2j} \\ i \neq l}} e_{Qi} + Q_{2l} - \frac{B_C}{2} z_{1j}^2 \right)^2}{z_{2j}^2} - \frac{B_C}{2} (z_{1j}^2 + z_{2j}^2) \quad (6.64)$$

Wartości wskaźników niezbilansowania określone wzorami (6.61) - (6.64) różnią się od wartości, występujących w przypadku rzeczywistym opisanym w rozdz. 6.2.7, o wartości odpowiednich danych pomiarowych o przepływach mocy czynnej albo biernej. W zależności od tego, jakie wartości przyjmują te dane, moduły wskaźników niezbilansowania mogą przyjmować znaczne wartości.

6.2.11. Podsumowanie

Przeprowadzona analiza wskaźników niezbilansowania dla węzłów i gałęzi pozwoliła wykryć pewne charakterystyczne cechy opisu systemu elektroenergetycznego z wykorzystaniem tych wskaźników, przydatne przy weryfikacji topologii. Rozpatrując przypadek idealny, tj. brak błędów obarczających dane pomiarowe, można stwierdzić, że:

1. W przypadku braku błędów topologii wskaźniki niezbilansowania dla dowolnego węzła, jak również dla dowolnej gałęzi (po skorygowaniu) są równe zeru.
2. W przypadku nieuwzględnienia j – tej gałęzi w modelu, gdy jest ona w rzeczywistości włączona:
 - wartości wskaźników niezbilansowania dla każdego węzła końcowego gałęzi są – ogólnie biorąc – różne od zera, określone przez wartości przepływów mocy w gałęzi,
 - wartości wskaźników niezbilansowania dla każdego węzła, który nie jest węzłem końcowym j – tej gałęzi, są równe zeru,
 - wartości wskaźników niezbilansowania dla j – tej gałęzi są równe zeru,
 - wartości wskaźników niezbilansowania dla innych gałęzi, dochodzących do węzłów końcowych rozpatrywanej j – tej gałęzi, są różne od zera i wartości ich wynikają z wartości przepływów mocy w j – tej gałęzi.
3. W przypadku uwzględnienia j – tej gałęzi w modelu, gdy jest ona w rzeczywistości wyłączona wartości wskaźników niezbilansowania dla węzłów końcowych j – tej gałęzi, jak również dla dowolnej gałęzi dochodzącej do węzłów końcowych j – tej gałęzi są takie, jak w przypadku braku błędów topologii.

W przypadku rzeczywistym należy wziąć pod uwagę wpływ błędów obarczających dane pomiarowe na wartości wskaźników niezbilansowania dla węzłów i gałęzi.

Należy zauważyć, że opis systemu elektroenergetycznego z wykorzystaniem wskaźników niezbilansowania dla węzłów i gałęzi nie pozwala rozróżnić pomiędzy sobą przypadków braku błędów topologii oraz uwzględnienia w modelu gałęzi, która jest w rzeczywistości wyłączona. Taki jednak przypadek błędu topologii można łatwo wykryć, testując wartości przepływów mocy na końcach gałęzi. Gdy są one jednocześnie – w przypadku idealnym - równe zeru, albo – w przypadku rzeczywistym – dostatecznie bliskie zeru, można wnioskować o tym, że gałąź jest w rzeczywistości wyłączona.

Do przypadku nieuwzględnienia rzeczywiście włączonej gałęzi można sprowadzić przypadek podziału jednego węzła np. na dwa inne. W tym przypadku podział węzła można traktować, jako nieuwzględnienie gałęzi o zerowych parametrach R , X_L , B_C pomiędzy rozpatrywanymi w modelu węzłami. Oznacza to, że wskazany błąd może być wykryty w oparciu o analizę wskaźników niezbilansowania dla węzłów i gałęzi.

W przeprowadzonej analizie wzięto pod uwagę przypadek pojedynczego błędu topologii. Sytuacja komplikuje się wtedy, gdy występuje wiele błędów topologii. Należy oczekiwać, że w tej sytuacji zastosowanie sztucznych sieci neuronowych pozwoli efektywnie roz-


wiązać problem weryfikacji topologii, który może być rozpatrywany jako problem klasyfikacji danych.

W przeprowadzonej analizie wyodrębniono dwa wskaźniki niezbilansowania mocy czynnej i dwa wskaźniki niezbilansowania mocy biernej dla gałęzi. Jednak w dalszej części pracy dla gałęzi rozpatruje się jeden wskaźnik niezbilansowania mocy czynnej i jeden wskaźnik niezbilansowania mocy biernej. Rozpatrywane wskaźniki stanowią średnie arytmetyczne odpowiednich par wskaźników, które wcześniej były brane pod uwagę.

6.3. Idea nowej metody

6.3.1. Ogólna charakterystyka

Ideę nowej metody weryfikacji topologii systemu elektroenergetycznego przedstawia rys. 6.2




Rys. 6.2. Idea nowej metody weryfikacji topologii systemu elektroenergetycznego.

Na podstawie danych pomiarowych o przepływach mocy czynnej i biernej na końcach gałęzi a także poziomów napięcia w węzłach sieci elektroenergetycznej wyznaczone są wskaźniki niezbilansowania dla wszystkich węzłów oraz gałęzi. Następnie podlegają one klasyfikacji we wstępnym klasyfikatorze. Wyniki klasyfikacji wstępnej są podawane na klasyfikatory lokalne, skojarzone z poszczególnymi węzłami. Ostateczną decyzję o poprawności in-

formacji o topologii podejmuje globalny blok decyzyjny na podstawie wyników klasyfikacji uzyskanych z lokalnych klasyfikatorów.

6.3.2. Blok wstępnej klasyfikacji

Strukturę bloku wstępnej klasyfikacji przedstawiono na rys. 6.3. Do realizacji klasyfikatora wybrano sieć neuronów z radialną funkcją bazową (*Radial Basis Function* – RBF). Sieć dokonuje klasyfikacji wskaźników niezbilansowania węzłów i gałęzi.



Rys. 6.3. Wstępny klasyfikator.

Funkcja aktywacji neuronów jest tak dobrana, aby jej wartość maksymalna była osiągnięta dla zerowej wartości wskaźników niezbilansowania węzłów oraz gałęzi. Jedną z możliwych postaci funkcji aktywacji neuronów, jest funkcja postaci:

$$\ell(x) = \begin{cases} 1 & \text{dla } x = 0 \\ 0 & \text{dla } x \neq 0 \end{cases} \quad (6.65)$$

Jednak tak określona funkcja nie ma w praktyce zastosowania, gdyż w rzeczywistych warunkach dane pomiarowe są obarczone błędami i wskaźniki niezbilansowania węzłów oraz gałęzi (poza przypadkami kiedy np. w wyniku błędu topologii istotnie różnią się one od zera) będą przyjmowały wartości zbliżone do zera. Przez analogię do rozkładu normalnego, jakim najczęściej opisuje się błędy pomiarowe, zastosowano funkcję Gaussa jako funkcję aktywacji neuronów klasyfikatora wstępnego:

$$f(x) = e^{-\frac{x^2}{2\sigma^2}}, \quad (6.66)$$

gdzie:

σ – parametr odpowiedzialny za szerokość krzywej.

Wartość funkcji bazowej jest w istocie miarą odległości wartości wskaźnika niezbilansowania węzła bądź gałęzi od wartości zerowej.

Dobór parametru szerokości funkcji aktywacji

W celu zapewnienia poprawności działania klasyfikatora w obecności błędów obarczających dane pomiarowe zachodzi konieczność doboru odpowiedniej szerokości funkcji aktywacji.

Parametr określający szerokość krzywej wiązany jest z wariancjami danych pomiarowych wielkości, które uwzględniane są przy definiowaniu odpowiedniego wskaźnika niezbilansowania. Zakładając niezależność błędów obarczających dane pomiarowe wielkości P_i $i \in I_k$ występujące we wzorze (6.7), wariancję wskaźnika niezbilansowania W_{Pk} , tj. wariancję sumy $\sum_{i \in I_k} P_i$ można określić wzorem

$$\sigma_{W_{Pk}}^2 = \sum_{i \in I_k} \sigma_{P_i}^2, \quad (6.67)$$

gdzie:

$\sigma_{P_i}^2$ – wariancja błędów obarczających dane pomiarowe przepływu mocy P_i .

Parametr określający szerokość funkcji aktywacji neuronu klasyfikatora wstępnego, na którego wejście podawany jest wynik obliczenia wskaźnika niezbilansowania mocy czynnej dla k -tego węzła W_{Pk} , jest określany następująco:

$$\sigma_{K_W_{Pk}} = \sqrt{a \sigma_{W_{Pk}}^2}, \quad (6.68)$$

gdzie:

a – współczynnik korekcyjny.

Podobnie parametr określający szerokość funkcji aktywacji neuronu klasyfikatora wstępnego, na którego wejście podawany jest wynik obliczenia wskaźnika niezbilansowania mocy biernej dla k -tego węzła W_{Qk} , jest określany wzorem:

$$\sigma_{K_W_{Qk}} = \sqrt{a \sigma_{W_{Qk}}^2}, \quad (6.69)$$

gdzie:

$$\sigma_{W_{Qk}}^2 = \sum_{i \in I_k} \sigma_{Q_i}^2, \quad (6.70)$$

$\sigma_{Q_i}^2$ – wariancja błędów obarczających dane pomiarowe przepływu mocy Q_i .

Parametry określające szerokości funkcji aktywacji neuronów klasyfikatora wstępnego, na których wejścia podawane są wyniki obliczenia odpowiednio wskaźników niezbilansowania mocy czynnej oraz biernej dla j -tej gałęzi W_{LjP1} , W_{LjQ1} są określone wzorami:

$$\sigma_{K_WLjP1} = \sqrt{a(\sigma_{W_{P1}}^2 + \sigma_{W_{P2}}^2)}, \quad (6.71)$$

$$\sigma_{K_WLjQ1} = \sqrt{a(\sigma_{W_{Q1}}^2 + \sigma_{W_{Q2}}^2)}, \quad (6.72)$$

gdzie:

$\sigma_{W_{P1}}^2, \sigma_{W_{P2}}^2$ - wariancje wskaźników niezbilansowania mocy czynnych odpowiednio w węźle początkowym i końcowym gałęzi,

$\sigma_{W_{Q1}}^2, \sigma_{W_{Q2}}^2$ - wariancje wskaźników niezbilansowania mocy biernych odpowiednio w węźle początkowym i końcowym gałęzi.

Dobór współczynnika korekcyjnego

Wartość współczynnika korekcyjnego wyznaczono doświadczalnie według następującej procedury:

- generowanie danych pomiarowych przepływów mocy z nałożonymi błędami przypadkowymi o rozkładzie normalnym ze znaną wariancją i wartością średnią. Do obliczeń przyjęto liczbę zbiorów danych pomiarowych $n = 50$,
- wyznaczenie, na podstawie analizy danych, liczby i rozmieszczenia spodziewanych wyników klasyfikacji. Rozpatrzono przypadki, gdy wszystkie bilanse mocy są spełnione oraz przypadki nieuwzględnienia w modelu pojedynczych gałęzi (symulacja obecności błędów topologii),
- określenie zakresu i kroku zmian wartości współczynnika korekcyjnego a . Do obliczeń przyjęto zakres $a \in (0,5; 10)$ z krokiem 0,1,
- wyznaczenie wskaźników niezbilansowania dla węzłów i dla gałęzi,
- przeprowadzenie obliczeń dla różnych wartości współczynnika korekcyjnego oddzielenie dla wskaźników niezbilansowania mocy czynnych (a_P) i biernych (a_Q) dla węzłów, wskaźników niezbilansowania mocy czynnych (a_{LP}) i biernych (a_{LQ}) dla gałęzi,
- przyjęcie za poprawną najmniejszej wartości współczynnika korekcyjnego, dla której uzyskiwane są poprawne wyniki klasyfikacji. Duże wartości współczynnika powodują zwiększenie szerokości funkcji bazowej i w rezultacie niepoprawne klasyfikacje,

- przeprowadzenie klasyfikacji dla wszystkich zestawów danych z wyznaczeniem dla każdego z nich optymalnej wartości α ,
- wyznaczenie średniej wartości współczynnika korekcyjnego uzyskanych dla wszystkich zestawów danych.

Przeprowadzone obliczenia wskazywały na niewielkie różnice wartości współczynnika korekcyjnego między poszczególnymi zestawami danych. Do dalszych obliczeń przyjęto:

$$\alpha_P=4; \alpha_{LP}=4; \alpha_Q=3,2; \alpha_{LQ}=3,2. \quad (6.73)$$

Działanie klasyfikatora wstępnego

Klasyfikator wstępny dokonuje odwzorowania wskaźników niebilansowania mocy czynnych i biernych dla węzłów oraz wskaźników niebilansowania mocy czynnych i biernych dla gałęzi na przedział $(0, 1)$. Dzięki temu możliwe jest uniezależnienie działania klasyfikatorów lokalnych od wartości danych pomiarowych.

Istotną własnością klasyfikatora wstępnego jest przyjmowanie przez funkcję bazową wartości z przedziału $(0, 1)$. Dzięki temu niepotrzebne jest przeprowadzanie normalizacji danych pomiarowych.

Przykładowe wyniki klasyfikacji wskaźnika niebilansowania mocy czynnych jednego z węzłów systemu testowego IEEE-14 dla zbioru danych pomiarowych obciążonych małymi błędami przedstawia rys.6.4.


Wyniki klasyfikacji tworzą dwie wyraźnie oddzielone grupy (klastry). Dzięki tej własności, a także przyjmowaniu wartości z ograniczonego zakresu (tj. z przedziału $(0, 1)$), wyniki klasyfikacji wstępnej mogą być użyte do dalszej klasyfikacji bez konieczności dodatkowego ich przetwarzania.

6.3.3. Lokalny klasyfikator topologii

Klasyfikatory lokalne skojarzone są z poszczególnymi węzłami sieci. Lokalny charakter błędu topologii wykorzystano przy określaniu zmiennych wejściowych i wyjściowych lokalnego klasyfikatora:

- **wejścia klasyfikatora lokalnego** – wyniki wstępnej klasyfikacji wskaźników niebilansowania mocy czynnych i biernych dla danego węzła, węzłów połączonych z danym węzłem poprzez gałęzie incydentne z nim oraz wskaźników niebilansowania mocy czynnych i biernych dla tych gałęzi.

Ilość wejść n_{wek} klasyfikatora skojarzonego z węzłem k można wyznaczyć z zależności:



Rys. 6.4. Wyniki na wyjściach wstępnych klasyfikatorów, gdy na ich wejścia podawane są wskaźniki niezbilansowania węzłów dla mocy czynnej i biernej w przypadku występowania małych błędów danych pomiarowych.

$$n_{wek} = 2(L_k + N_k + 1), \quad (6.74)$$

gdzie:

L_k – liczba gałęzi incydentnych do węzła k ;

N_k – liczba węzłów połączonych z węzłem k .

- **wyjścia klasyfikatora lokalnego** – wyniki klasyfikacji poprawności uwzględnienia gałęzi w modelu systemu elektroenergetycznego. Liczba wyjść wynosi L_k .

Technika realizacji lokalnego klasyfikatora

Do realizacji lokalnego klasyfikatora topologii wykorzystano wielowarstwową, jednokierunkową sztuczną sieć neuronową z sigmoidalną, bipolarną (tangens hiperboliczny) funkcją aktywacji.

Sieci neuronowe są szeroko wykorzystywane w celu klasyfikacji danych do określonych grup. Wśród ich własności wskazać można na następujące, które są szczególnie istotne z punktu widzenia nowej metody weryfikacji topologii:

- odnajdywanie zależności wiążących zbiorów danych wejściowych i wyjściowych zwłaszcza, gdy złożoność problemu nie pozwala na jego opis analityczny lub opis ten jest trudny do określenia. Wyznaczenie zależności między danymi pomiarowymi a topologią systemu elektroenergetycznego o złożonej strukturze wtedy, gdy istnieje możliwość występowania

błędów obarczających dane pomiarowe, jest zwykle bardzo trudne. Zastosowanie sieci neuronowych może rozwiązać szereg problemów z tym związanych,


- możliwość klasyfikacji wzorców do wyodrębnionych grup wektorów danych wejściowych bez konieczności stosowania dodatkowej analizy (np. testowania hipotez statystycznych),
- dostarczanie poprawnych wyników nawet w przypadku wystąpienia zaszumionych lub obarczonych dużymi błędami danych. Jest to możliwe dzięki istnieniu dużej liczby połączeń między poszczególnymi neuronami. Czyni to sieć stosunkowo odporną na zakłócenia.
- własności uogólniania, tj. dostarczania poprawnych wyników dla przypadków nie uwzględnionych w zbiorze uczącym. Poprawnie nauczona sieć neuronowa działa jako interpolator stosując wiedzę o zbiorze danych zawartą w architekturze i wagach połączeń ustalonych w trakcie uczenia,
- duża szybkość działania wynikająca z równoległego przetwarzania informacji. Przetwarzanie opiera się na równoległym wykonywaniu szeregu stosunkowo prostych operacji. Nie jest konieczne stosowanie czasochłonnych i złożonych obliczeniowo procedur obliczeniowych. Dzięki sprzętowej implementacji sieci neuronowych możliwe jest uzyskanie bardzo dużych szybkości działania,

Spośród niedogodności stosowania sztucznych sieci neuronowych wyróżnić można:

- brak prostych procedur określania architektury sieci. Zwykle wiąże się to z tworzeniem szeregu sieci o różnej architekturze i wybór sieci o najlepszych własnościach,
- konieczność dysponowania odpowiednio licznym i reprezentatywnym zbiorem danych uczących, którego uzyskanie nie zawsze jest możliwe w praktyce.

Struktura lokalnego klasyfikatora

Strukturę lokalnego klasyfikatora topologii przedstawiono na rys. 6.5.



Rys. 6.5. Schemat sieci neuronowej wstępnego klasyfikatora

Klasyfikator lokalny stanowi sztuczna sieć neuronowa, na której wejścia podawane są wyniki wstępnej klasyfikacji wskaźników niezbilansowania dla węzłów oraz gałęzi.

Lokalny blok decyzyjny

Na wyjściach klasyfikatora lokalnego pojawiają się wyniki klasyfikacji poprawności uwzględnienia gałęzi w modelu systemu elektroenergetycznego. Ponieważ w praktyce wartości wyjść sieci neuronowej nie przyjmują wartości dyskretnych, konieczne jest ustalenie progów dla poszczególnych decyzji. Przyjęte zakresy zestawiono w tab. 6.1.

Tab. 6.1. Znaczenie stanów na wyjściach lokalnego klasyfikatora

Wartości progów	Decyzja
$1 < Y_{kj} < 0,5$	D_p – decyzja „poprawne uwzględnienie gałęzi w modelu”
$0,5 \leq Y_{kj} \leq -0,5$	D_0 – wstrzymanie od podjęcia decyzji „poprawne uwzględnienie gałęzi w modelu” jak również decyzji „niepoprawne uwzględnienie gałęzi w modelu”
$-0,5 < Y_{kj} < -1$	D_b – decyzja „niepoprawne uwzględnienie gałęzi w modelu”

Y_{kj} – wyjście lokalnego klasyfikatora odpowiadające gałęzi j skojarzonego z węzłem k

Zastosowaniu bipolarnej sigmoidalnej funkcji aktywacji, pozwala na uzyskanie zakresu wartości $Y_{kj} \in (-1; 1)$. Możliwe jest przez to uzyskanie szerszych niż w przypadku funkcji unipolarnej przedziałów decyzyjnych.

6.3.4. Blok globalnej klasyfikacji

Każdy lokalny klasyfikator skojarzony jest z jednym węzłem. Na jego wyjściach otrzymywane są decyzje o poprawności uwzględnienia w modelu systemu elektroenergetycznego incydentnych do niego gałęzi. Jeżeli gałąź jest incydentna do dwóch węzłów, można wyróżnić dwa klasyfikatory lokalne, na których wyjściach podawane są decyzje o poprawności uwzględnienia w modelu tej gałęzi.

Blok globalnej klasyfikacji realizuje zadanie zbierania wyników klasyfikacji z poszczególnych klasyfikatorów lokalnych oraz ustalania na ich podstawie ostatecznych decyzji o poprawności uwzględnienia w modelu systemu elektroenergetycznego rozpatrywanych gałęzi. Wyniki klasyfikacji klasyfikatorów lokalnych dotyczących tej samej gałęzi mogą się różnić, ustalona została więc reguła decyzyjna w celu ustalenia ostatecznej decyzji (decyzji globalnej) na podstawie decyzji lokalnych.

Reguła ta jest następująca:

$$D_{GL} = \begin{cases} D_p & \text{gdy } (D_{pLk} \wedge D_{pLm}) \vee (D_{pLk} \wedge D_{OLm}) \vee (D_{OLk} \wedge D_{pLm}) \\ D_O & \text{gdy } (D_{pLk} \wedge D_{bLm}) \vee (D_{bLk} \wedge D_{pLm}) \vee (D_{OLk} \wedge D_{OLm}), \\ D_b & \text{gdy } (D_{bLk} \wedge D_{bLm}) \vee (D_{bLk} \wedge D_{OLm}) \vee (D_{OLk} \wedge D_{bLm}) \end{cases} \quad (6.75)$$

gdzie:

D_{GL} – globalna decyzja weryfikacyjna w odniesieniu do gałęzi L ;

D_p , D_b , D_O – decyzje weryfikacyjne; D_p – decyzja: „Gałąź jest właściwie uwzględniona w modelu”, D_b – decyzja: „Gałąź nie jest właściwie uwzględniona w modelu”, D_O – brak możliwości podjęcia decyzji D_p albo D_b ,

D_{pLk} , D_{bLk} , D_{OLk} – decyzje lokalnego klasyfikatora skojarzonego z węzłem k ,

D_{pLm} , D_{bLm} , D_{OLm} – decyzje lokalnego klasyfikatora skojarzonego z węzłem m ,

D_{pLk} , D_{pLm} – decyzje „Gałąź L jest właściwie uwzględniona w modelu”,

D_{bLk} , D_{bLm} – decyzje „Gałąź L nie jest właściwie uwzględniona w modelu”,

D_{OLk} , D_{OLm} – brak możliwości podjęcia decyzji D_{pLk} , D_{pLm} albo D_{bLk} , D_{bLm} .

Decyzja „Gałąź L jest właściwie uwzględniona w modelu” jest podejmowana w przypadku, gdy wyniki obu klasyfikacji lokalnych wskazują na poprawne uwzględnienie gałęzi w modelu, bądź też jeden z nich wskazuje na poprawne uwzględnienie gałęzi

w modelu, zaś drugi sygnalizuje brak możliwości podjęcia decyzji. Podobna sytuacja występuje w przypadku decyzji „Gałąź nie jest właściwie uwzględniona w modelu”. Jest ona podejmowana w przypadku, gdy wyniki obu klasyfikacji lokalnych wskazują na błędne uwzględnienie gałęzi w modelu, bądź też jeden z nich wskazuje na błędne uwzględnienie gałęzi w modelu, zaś drugi sygnalizuje brak możliwości podjęcia decyzji.

Wstrzymanie się od decyzji o poprawności uwzględnienia gałęzi w modelu występuje wtedy, gdy klasyfikatory lokalne dostarczają sprzecznych decyzji albo też oba sygnalizują wstrzymanie się od decyzji.

6.4. Problemy realizacji klasyfikatorów lokalnych

6.4.1. Tworzenie zbioru uczącego

Klasyfikator lokalny realizuje w istocie proces klasyfikacji danych wejściowych (wyników wstępnej klasyfikacji wskaźników niezbilansownia dla węzłów i gałęzi) do wyodrębnionych grup. Zbiór uczący powinien więc zawierać elementy należące do każdej z wydzielonych klas. Pozwoli to przy uczeniu na taki dobór wag sieci, który zapewni odpowiednie usytuowanie grup danych w wielowymiarowej przestrzeni danych. Jednocześnie konieczne jest zapewnienie poprawnej klasyfikacji także dla danych spoza zbioru uczącego (uogólnienie). Podobne sygnały wejściowe powinny powodować powstawanie podobnych odpowiedzi. Jedną z metod uzyskania dobrych własności uogólniających sieci jest dodanie zaszumienia do danych uczących. Sygnały na wyjściu sieci nie powinny ulegać zmianom, gdy zmiany sygnałów wejściowych mieszczą się w pewnym zakresie. W praktyce odpowiada to występowaniu błędów przypadkowych danych pomiarowych. Sposób ten zastosowano przy konstrukcji zbioru uczącego.

Można więc wyodrębnić dwie główne cechy zbioru uczącego:

- kompletność (reprezentatywność),
- zapewnienie własności uogólniających.

Przy tworzeniu zbioru uczącego dla klasyfikatora lokalnego skojarzonego z wyróżnionym węzłem zapewniono:

- uwzględnienie różnych konfiguracji połączenia węzła z resztą sieci – za pomocą programu do obliczeń rozptylowych obliczono rozptywy mocy i poziomy napięcie dla różnych konfiguracji,

- pominięcie przypadku, w którym rozpatrywany węzeł jest izolowany od reszty sieci - brano pod uwagę tylko takie przypadki, w których jest on połączony z resztą sieci elektroenergetycznej przynajmniej poprzez jedną gałąź; przykładowe zestawienie różnych konfiguracji sieci w bezpośrednim sąsiedztwie węzła nr 2 systemu testowego IEEE-14 przedstawiono w tab. 6.2,

Tab. 6.2. Zestawienie konfiguracji sieci w bezpośrednim sąsiedztwie węzła nr 2 systemu testowego IEEE-14.

Numer konfiguracji	Numery gałęzi wyłączonych
1	3, 4, 5
2	1, 4, 5
3	4, 5
4	1, 3, 5
5	3, 5
6	1, 5
7	5
8	1, 3, 4
9	3, 4
10	1, 4
11	4
12	1, 3
13	3
14	1
15	wszystkie gałęzie załączone

- symulowanie wystąpienia pojedynczych i wielokrotnych błędów nieuwzględnienia w modelu systemu gałęzi w rzeczywistości załączonej,
- uwzględnienie zmian obciążenia w systemie elektroenergetycznym - zmiana poziomu obciążenia w granicach 70% – 110% obciążenia przyjętego za bazowe,
- modelowanie błędów przypadkowych obarczających dane pomiarowe przepływów mocy zgodnie z rozkładem normalnym o standardowym odchyleniu [14]:

$$\sigma = \frac{1}{3} (2\%|M| + 0,35\% FS) \quad (6.76)$$

gdzie:

M – wartość danej pomiarowej,

FS – zakres pomiarowy.

Zakres pomiarowy FS przyjęto na poziomie 200 MW dla mocy czynnej i 100 MVar dla mocy biernej.

- modelowanie błędów przypadkowych obarczających dane pomiarowe poziomów napięcia zgodnie z rozkładem normalnym i standardowym odchyleniem:

$$\sigma = 1\%|M|, \quad (6.77)$$

gdzie:

M – wartość danej pomiarowej napięcia.

Na podstawie zbiorów danych pomiarowych utworzonych przy uwzględnieniu podanych założeń obliczane były wskaźniki niezbilansowania mocy czynnej i biernej dla węzłów oraz gałęzi. Wskaźniki te były poddane klasyfikacji wstępnej. Z wyników klasyfikacji wstępnej ostatecznie tworzone były zbiory uczące dla klasyfikatorów lokalnych.

6.4.2. Sposób i przebieg uczenia

Algorytm nowej metody weryfikacji topologii zaimplementowano w środowisku MATLAB. Uczenie sieci przeprowadzono za pomocą algorytmu największego spadku z adaptacyjnym współczynnikiem uczenia. Pozwala on na znacznie szybsze uczenie sieci, aniżeli jest to w przypadku metody ze stałym współczynnikiem w trakcie uczenia. W metodzie adaptacyjnej na podstawie wartości błędu wyrażonego przez sumę kwadratów różnic między wartościami na wyjściu sieci a wartościami spodziewanymi [13]:

$$e = \sqrt{\sum_{i=1}^N (y_i - d_i)^2}, \quad (6.78)$$

gdzie:

e – suma kwadratów błędów;

y_i – wartość na wyjściu sieci,

d_i – wartość spodziewana na wyjściu,

N – liczba wyjść.

określa się sposób zmian wartości współczynnika uczenia. Współczynnik uczenia η jest w trakcie uczenia stopniowo zwiększany, przy jednoczesnym sprawdzaniu, czy błąd e nie rośnie w porównaniu z błędem wyznaczonym dla poprzedniej wartości współczynnika uczenia. Jeśli błąd uczenia e_j w j -tej iteracji jest większy dla błędu w $j-1$ iteracji, przy czym:

$$e_j > k e_{j-1}, \quad (6.79)$$

gdzie:

k – współczynnik dopuszczalnych zmian błędu,

następuje zmniejszenie współczynnika uczenia, według zależności:

$$\eta_{j+1} = k_d \eta_j, \quad (6.80)$$

gdzie:

k_d – współczynnik zmniejszania wartości η .

W przypadku, gdy

$$e_j \leq k e_{j-1} \quad (6.81)$$

współczynnik uczenia zwiększa się zgodnie zależnością:


$$\eta_{j+1} = k_g \eta_j \quad (6.82)$$

gdzie:


k_g – współczynnik zwiększania wartości η .

W czasie procesu uczenia sztucznych sieci neuronowych klasyfikatorów lokalnych przyjmowano następujące wartości współczynników k ; k_d oraz k_g : $k=1,04$; $k_d=0,7$, $k_g=1,05$.

Przykładowy przebieg uczenia z adaptacyjnym współczynnikiem uczenia dla sieci neuronowej skojarzonej z węzłem nr 3 systemu testowego IEEE-14 przedstawiono na rys. 6.7. Na rysunku tym łatwo zaobserwować, że na początku uczenia następuje szybkie zwiększanie się współczynnika uczenia. Jest to charakterystyczne dla tego sposobu uczenia sieci neuronowych. Po ustaleniu się wartości przeciętnej współczynnika uczenia na pewnym określonym poziomie, jego wartość zwiększa się i zmniejsza w następujących po sobie iteracjach. Dla porównania przedstawiono przebieg uczenia w przypadku metody ze stałym współczynnikiem uczenia (rys. 6.6).



Rys. 6.6. Przebieg uczenia dla stałego współczynnika uczenia.



Rys. 6.7. Przebieg uczenia z adaptacyjnym współczynnikiem uczenia.

6.4.3. Wybór architektury sztucznej sieci neuronowej

Wybór odpowiedniej architektury sprowadza się do problemu wyznaczenia liczby neuronów w warstwie ukrytej n_H . Ich liczba nie może być zbyt mała, gdyż sieć nie będzie w stanie nauczyć się rozwiązania problemu. Z kolei zbyt duża ich liczba prowadzi do nadmiernego dopasowania do danych i złych własności uogólniania sieci.

Na podstawie testów stwierdzono, że istnieje pewna optymalna liczba neuronów w warstwie ukrytej pozwalająca na:

- przeprowadzenie procesu uczenia do momentu osiągnięcia ustalonej wartości błędu (kolejne epoki nie powodują istotnego zmniejszenia jego wartości) lub, gdy błąd średniokwadratowy (*Mean Square Error* – MSE) osiągnie wartość rzędu 10^{-5} ,
- uzyskanie dobrych własności uogólniających.

Proces doboru liczby neuronów w warstwie ukrytej obejmował następujące etapy:

1. Wybranie małej początkowej liczby neuronów w warstwie ukrytej, np. $n_H=2$.
2. Przeprowadzenie uczenia.
3. Jeśli nie było możliwe nauczenie sieci, tj. osiągnięcie założonego poziomu błędu uczenia, przeprowadzenie ponownego uczenia dla sieci o większej liczbie neuronów.
4. W przypadku, gdy sieć się nauczyła, przeprowadzenie testowania własności uogólniających na zbiorze testowym, niezależnym od zbioru uczącego.

5. Zwiększenie liczby neuronów w warstwie ukrytej i powtórzenie procedury aż do wyraźnego pogarszania się własności uogólniania dla zbyt dużej liczby neuronów.

Przykładowe wyniki określania liczby neuronów w warstwie ukrytej dla klasyfikatora lokalnego skojarzonego w węzłem nr 1 systemu testowego IEEE-14 przedstawiono w tab. 6.3.

Tab. 6.3. Ustalanie liczby neuronów w warstwie ukrytej

n_H	Klasyfikacje odpowiadające brakowi decyzji [%]	Klasyfikacje odpowiadające błędnej decyzji [%]
3	0,04	0,04
4	0,00	0,00
5	0,00	0,00
6	0,07	0,02

Najlepsze wyniki uzyskuje się dla n_H równej 4 lub 5. W przypadku zbyt dużej liczby neuronów sieć neuronowa nadmiernie dopasowuje się do danych, co negatywnie wpływa na jej własności uogólniające. Z kolei zbyt mała liczba neuronów prowadzi do tego, że sieć nie jest w stanie nauczyć się poprawnej klasyfikacji.

Opisany sposób ustalania liczby neuronów w warstwie ukrytej zastosowano dla wszystkich sieci neuronowych klasyfikatorów lokalnych. Wyniki doboru liczby ukrytych neuronów zestawiono w tab. 6.4.

Tab.6.4. Charakterystyka sieci neuronowych klasyfikatorów lokalnych

Numer węzła	Liczba wejść klasyfikatora	Liczba wyjść klasyfikatora	Liczba neuronów w warstwie ukrytej n_H
1	10	2	4
2	18	4	8
3	10	2	4
4	22	5	10
5	18	4	8
6	18	4	8
7	14	3	6
8	6	1	2
9	18	4	8
10	10	2	4
11	10	2	4
12	10	2	4
13	14	3	6
14	10	2	4

6.4.4. Testowanie działania klasyfikatorów lokalnych

W celu przetestowania własności uogólniających klasyfikatorów lokalnych zastosowano, niezależne od zbioru uczącego, zbiory testowe, zawierające przykłady nie uwzględnione przy uczeniu sieci neuronowej. Wyniki klasyfikacji dla poszczególnych gałęzi przedstawia tab. 6.5. Liczbę wektorów testowych dla każdego z węzłów prezentuje tab. 6.6.

Tab. 6.5. Wyniki klasyfikacji dla poszczególnych gałęzi

Numer gałęzi	Klasyfikacje odpowiadające brakowi decyzji [%]	Klasyfikacje odpowiadające błędnej decyzji [%]
1	0,00	0,00
2	0,00	0,01
3	0,01	0,00
4	0,05	0,01
5	0,03	0,01
6	0,05	0,02
7	0,01	0,00
8	0,08	0,00
9	0,55	0,88
10	0,01	0,00
11	0,10	0,00
12	0,06	0,00
13	0,46	0,00
14	0,07	0,00
15	0,35	0,01
16	0,25	0,04
17	0,07	0,00
18	0,19	0,05
19	2,93	1,48
20	1,55	0,10

Tab. 6.6. Liczba wektorów testowych użytych do testowania działania klasyfikatorów lokalnych

Nr klasyfikatora	Liczba wektorów testowych w serii
1	8335
2	21653
3	4170
4	25680
5	16250
6	16250
7	7505
8	750
9	16200
10	6250
11	6250
12	6250
13	10185
14	6250

Wyniki testowania wskazują na dobre własności uogólniające sieci neuronowych klasyfikatorów lokalnych. Związane jest to ze stworzeniem odpowiednio licznych i reprezentatywnych zbiorów uczących oraz starannym doбором architektury sieci neuronowych. Wprowadzenie szumu do danych wejściowych, modelujących występowanie przypadkowych błędów danych pomiarowych wpłynęło korzystnie na działanie klasyfikatorów.

Obserwowany jest większy poziom błędnych klasyfikacji i wstrzymywania się od decyzji dla klasyfikatorów skojarzonych z węzłami połączonych z gałęziami, w których występują bardzo małe wartości przepływów. Małe wartości przepływów w załączonych gałęziach mogą być interpretowane. Wstępne klasyfikatory mogą wtedy dostarczać nieprawidłowych klasyfikacji, gdyż nieuwzględnienie w modelu gałęzi o małym przepływie może nie mieć wpływu na spełnienie lub niespełnienie związków i w efekcie lokalny klasyfikator generuje niepoprawną decyzję.

6.5. Przykład wykorzystania metody

Wykorzystując opracowaną metodę przeprowadzono przykładową weryfikację topologii systemu testowego IEEE-14, przedstawionego w dodatku A. Założono, że:

1. Wszystkie gałęzie w systemie testowym są włączone.
2. W modelu topologii systemu:

- a) nie zostały uwzględnione wszystkie gałęzie dochodzące do węzła nr 9,
- b) nie został uwzględniony kompensator synchroniczny podłączony do węzła nr 8, tj. nie została uwzględniona gałąź nr 14,
- c) nie została uwzględniona gałąź nr 12.

Założenia oznaczają, że w modelu topologii występuje 6 błędów topologii. Założenie 2a nawiązuje do sytuacji, gdy telesygnały pochodzące ze stacji elektroenergetycznej odpowiadającej węzłowi nr 9 są błędne lub niedostępne.

Charakterystykę topologii systemu testowego oraz zakładanego modelu topologii dla tego systemu zawarto w tab. 6.7.

Wyniki weryfikacji topologii przedstawia tab. 6.8.

Tab. 6.7. Charakterystyka topologii systemu testowego oraz zakładanego modelu topologii.
+ -gałąź włączona; — - gałąź wyłączona.

Nr gałęzi	Rzeczywistość	Model
1	+	+
2	+	+
3	+	+
4	+	+
5	+	+
6	+	+
7	+	+
8	+	+
9	+	—
10	+	+
11	+	+
12	+	—
13	+	+
14	+	—
15	+	—
16	+	—
17	+	—
18	+	+
19	+	+
20	+	+

**Tab. 6.8. Wyniki weryfikacji topologii.
BT - błąd topologii.**

Nr gałęzi	Wyjście klasyfikatora		Decyzja ostateczna
	Węzeł początkowy	Węzeł końcowy	
1	0,9510	0,9509	
2	0,9504	0,9497	
3	0,9506	0,9550	
4	0,9504	0,9921	
5	0,9510	0,9987	
6	0,9474	0,9846	
7	0,9534	0,2198	
8	0,6320	0,9321	
9	-1,0000	-0,9466	BT
10	0,9368	0,9526	
11	0,9509	0,9887	
12	-0,9509	-0,9510	BT
13	0,9496	0,9934	
14	0,3205	-0,8399	BT
15	-0,9997	-0,9463	BT
16	-0,9535	-0,9483	BT
17	-0,9393	-0,9525	BT
18	0,9509	0,9711	
19	0,9999	0,9931	
20	0,8367	0,9486	

Wyniki zawarte w tab. 6.8 wskazują na to, że wszystkie podjęte decyzje weryfikacyjne są poprawne mimo, że założenie tak dużej liczby błędów topologii, jak to podano wyżej, spowodowało, że dla połowy wszystkich węzłów w systemie, tj. dla 7 węzłów obserwuje się niezbilansowanie mocy czynnych a dla 8 węzłów niezbilansowanie mocy biernych (por. tab. 6.9.).

Tab. 6.9. Wyniki na wyjściach wstępnych klasyfikatorów, gdy na ich wejścia podawane są wskaźniki niezbilansowania węzłów dla mocy czynnej i biernej

Nr węzła	Klasyfikacja wskaźnika niezbilansowania węzła dla mocy czynnej	
	Moc czynna	Moc bierna
1	1,0000	1,0000
2	1,0000	1,0000
3	1,0000	1,0000
4	0,0000	0,0021
5	1,0000	1,0000
6	0,0012	0,0095
7	0,0000	0,0000
8	1,0000	0,0000
9	0,0000	0,0000
10	0,0012	0,0000
11	1,0000	1,0000
12	0,0000	0,0002
13	1,0000	1,0000
14	0,0000	0,0000

Należy zwrócić uwagę na różnicę w klasyfikacji wskaźnika niezbilansowania dla mocy czynnej oraz wskaźnika niezbilansowania dla mocy biernej w odniesieniu do węzła nr 8. Spowodowane jest to niepoprawnym uwzględnieniem kompensatora synchronicznego. Pomińnięcie w modelu kompensatora wpłynęło jedynie na klasyfikację wskaźnika niezbilansowania dla mocy biernej. Dzięki uwzględnieniu przez testowaną metodę związków obejmujących także przepływy mocy biernej, możliwe było wykrycie błędnego uwzględnienia gałęzi, w której występuje element o charakterze reaktancyjnym. Własności tej nie posiadają metody uwzględniające jedynie dane pomiarowe o przepływach mocy czynnej [4], [52].

6.6. Własności metody

Na podstawie badań testowych określono następujące własności nowej metody weryfikacji topologii systemu elektroenergetycznego.

- Możliwość przeprowadzenia lokalnej weryfikacji topologii - dzięki zastosowaniu szeregu klasyfikatorów skojarzonych z poszczególnymi węzłami sieci i uwzględnieniem informacji z otoczenia danego węzła, uzyskano lokalny charakter metody weryfikacyjnej. Oprócz tego możliwe było zastosowanie sieci neuronowych o prostszej architekturze
- Możliwość wykrywania wielokrotnych błędów topologii – możliwe jest wykrywanie jednoczesnego niewłaściwego uwzględnienia w modelu kilku elementów systemu,
- Mała zależność od typu sieci – istnieje możliwość wykrywania błędów topologii w węzłach połączonych radialnie z resztą sieci, a także w zamkniętych układach połączeń,
- Możliwość wykrywania większej liczby typów błędów topologii aniżeli jest to możliwe za pomocą innych metod,
- Wykrywanie niewłaściwego uwzględnienia w modelu gałęzi o charakterze reaktancyjnym – dzięki uwzględnieniu związków odejmujących także dane pomiarowe mocy biernej możliwe jest wykrycie nieprawidłowego uwzględnienia elementów systemu o charakterze reaktancyjnym, np. baterii kondensatorów.
- Mała zależność od stanu pracy systemu – symulacje przeprowadzone dla różnych poziomów obciążeń w systemie wskazują, że zastosowany sposób przetwarzania danych pomiarowych jest niezależny od wartości przepływów. Wyjątek stanowią, przypadki bardzo małych wartości przepływów w załączonych gałęziach.
- Wykorzystanie związków obowiązujących w każdej sieci elektroenergetycznej.
- Wykorzystanie "surowych" danych pomiarowych.

Wśród niedoskonałości metody wskazać należy na:

- konieczność dysponowania pełnym zestawem danych pomiarowych,
- możliwość zidentyfikowania w rzeczywistości załączonej gałęzi z małą wartością przepływów jako wyłączonej w modelu,
- konieczność doboru i uczenia wielu sieci neuronowych, których liczba jest równa liczbie węzłów w sieci.

7. Elementy oryginalne rozprawy

- Klasyfikacja istniejących podejść do weryfikacji topologii systemu elektroenergetycznego, przyjmując jako kryterium rodzaj informacji wykorzystywanych przez te podejścia.
- Wykorzystanie podejścia opierającego się na zastosowaniu sztucznych sieci neuronowych zakładając, że zbiór danych pomiarowych z systemu elektroenergetycznego obejmuje nie tylko dane pomiarowe o przepływach mocy czynnej ale także i dane pomiarowe o przepływach mocy biernej i poziomach napięcia.
- Opracowanie nowego podejścia do weryfikacji topologii systemu elektroenergetycznego z wykorzystaniem oryginalnych wskaźników niebilansowania mocy czynnej i biernej dla węzłów i gałęzi.
- Opracowanie koncepcji wskaźników niebilansowania mocy czynnej i biernej dla węzłów i gałęzi systemu elektroenergetycznego.
- Przeprowadzenie analizy teoretycznej wskaźników niebilansowania mocy czynnej i biernej dla węzłów i gałęzi systemu elektroenergetycznego.
- Opracowanie idei nowej metody weryfikacji topologii systemu elektroenergetycznego.
- Opracowanie algorytmu weryfikacji topologii. Implementacja algorytmu weryfikacji topologii w środowisku MATLAB.
- Testowanie symulacyjne opracowanej metody w środowisku MATLAB.

8. Wnioski i plany przyszłych badań

Problem poprawności topologii jest jednym z bardziej istotnych problemów systemów elektroenergetycznych. Niepoprawna topologia systemu nie może być podstawą do podejmowania decyzji przez dyspozytorów w dyspozycji mocy. Nie może być podstawą do obliczeń, w których znajomość topologii jest niezbędna, a których wyniki stanowią ważny element kształtowania decyzji dyspozytora. Błędy topologii, tj. niewłaściwe uwzględnienie elementów systemu elektroenergetycznego w modelu tego systemu, zdarzają się stosunkowo rzadko. Konsekwencje ich wystąpienia są jednak bardzo poważne. W tym należy doszukiwać się przyczyny utrzymującego się wciąż zainteresowania nowymi bardziej efektywnymi metodami sprawdzania poprawności topologii. Przegląd metod weryfikacji topologii systemu elektroenergetycznego, podanych w literaturze, wskazuje, że nie można znaleźć metod, które spełniałyby wszystkie stawiane takim metodom wymagania.

Analiza literatury (doświadczeń innych badaczy) i przeprowadzone badania wskazują na to, że aby osiągnąć większą efektywność przy weryfikacji topologii systemu elektroenergetycznego, oprócz zastosowania odpowiednich technik obliczeniowych, które będą umożliwiały szybkie przetwarzanie dużej liczby danych oraz posiadać możliwości klasyfikacji danych, konieczne jest uwzględnienie w szerszym zakresie wiedzy o systemie elektroenergetycznym. Oznacza to szersze wykorzystanie związków opisujących system elektroenergetyczny i również szersze wykorzystanie odpowiednio bogatego zbioru danych pomiarowych.

Nawiązując do studiów literaturowych, w pracy zaproponowano nowe podejście do weryfikacji topologii systemu elektroenergetycznego, zakładające wykorzystanie oprócz danych pomiarowych o przepływach mocy czynnej także danych pomiarowych o przepływach mocy biernej i poziomach napięć w węzłach sieci elektroenergetycznej oraz zdefiniowanych na potrzeby weryfikacji topologii wskaźników niebilansowania mocy czynnej oraz mocy biernej dla węzłów i gałęzi. Analiza zaproponowanych wskaźników niebilansowania pokazała korzystne cechy opisu systemu elektroenergetycznego z wykorzystaniem tych wskaźników dla potrzeb weryfikacji topologii. Jednak w warunkach występowania błędów obarczających dane pomiarowe oraz możliwości występowania wielokrotnych błędów topologii wnioskowanie o poprawności topologii staje się złożone.

W tej sytuacji, biorąc dodatkowo pod uwagę to, że problem weryfikacji topologii można traktować jako problem klasyfikacji, postanowiono wykorzystać technikę sztucznych sieci neuronowych. Zaproponowane podejście pozwoliło opracować metodę weryfikacji topo-

logii, umożliwiającą wykrywanie błędów topologii, których nie można wykryć wykorzystując tylko dane pomiarowe o przepływach mocy czynnej. Z uwagi na wykorzystywanie szerokiej wiedzy o systemie elektroenergetycznym osiągnięto wysoką efektywność metody. Jednocześnie nastąpiło znaczne uproszczenie architektury i procesu uczenia zastosowanych sieci neuronowych. Sformułowana w pracy teza została więc udowodniona, stawiany cel należy uznać za osiągnięty.

Przewiduje się, że dalsze badania będą głównie koncentrowały się na:

- uwzględnieniu obecności grubych błędów obarczających dane pomiarowe wykorzystywane w czasie weryfikacji topologii systemu elektroenergetycznego, rozpatrzeniu możliwości weryfikacji topologii systemu elektroenergetycznego przy ograniczonym zbiorze danych pomiarowych.

9. Literatura

- [1] Abd-El-Aal Abd-El-Reheim Mohamed, *Power network topology recognition using neural networks*, Electric Machines and Power Systems, Vol. 27, No. 2, 1999, pp.195-208.
- [2] Abur A., Kim H., Çelik M. K., *Identifying the unknown circuit breaker statuses in power networks*, IEEE Transactions on Power Systems, Vol. 10, No. 4, November 1995, pp. 2029-2037.
- [3] Alsaç O., Vempati N., Stott B., Monticelli A., *Generalized state estimation*, IEEE Transactions on Power Systems, vol. 13, no. 3, August 1998, pp. 1069-1075.
- [4] Alves da Silva A. P., Quintana V. H., *Pattern analysis in power system state estimation*, Electrical Power and Energy Systems, vol. 17, No.1, 1995, pp. 51-60.
- [5] Atanasova T., Lubenova V., Zaprianov J., Nour-Eldin M., *Estimation of state variable in power system combining theoretical knowledge with RBF neural network*, [w:] Computational Intelligence in Systems and Control, Design and Applications, Ed. S.G. Tzafestas, NTUA, Greece, Kluwer Academic Publisher, 1999, pp. 193-200.
- [6] Bonanomi P., Gramberg G., *Power system data validation and state calculation by network search techniques*, IEEE Transactions on Power Apparatus and Systems, Vol. PAS-102, No. 1, January 1983, pp. 238-249.
- [7] Borkowska B., *How to deal with errors in network data*, Proceedings of the 7-th Power Systems Computation Conference, Lausanne, Switzerland, 12-17 July 1981, pp. 513-519.
- [8] Cegielski M., Wilkosz K., *Model systemu elektroenergetycznego dla potrzeb przedstymacyjnej weryfikacji topologii*, Archiwum Elektrotechniki, Tom XL, Zeszyt 3/4, 1991, str. 487-498.
- [9] Clements A., Costa A. S., *Topology error identification using normalized Lagrange multipliers*, IEEE Transactions on Power Systems, Vol. 13, No. 2, May 1998, pp. 347-353.
- [10] Clements A., Davis P. W., *Detection and identification of topology errors in electric power systems*, IEEE Transactions on Power Systems, Vol. 3, No. 4, November 1988, pp. 1748-1753.
- [11] Costa S., Leão J. A., *Identification of topology errors in power system state estimation*, IEEE Transactions on Power Systems, Vol. 8, No. 4, November 1993, pp. 1531-1538.
- [12] Delimar M., Hebel Z., Pavić I., *Power system topology identification using neural networks. Part I – line processing*, Proceedings of the IASTED International Conference Power and Energy Systems, November 19-22, 2001, Clearwater, Florida, USA, pp. 129-133.
- [13] Demuth H., Beale M., *Neural network toolbox for use with Matlab*, The Mathworks Inc., Natick 2000.
- [14] Dopazo J. F., Klitin O. A., Stagg G. W., Van Slyck L. S., *State calculation of power systems from line flow measurements*, IEEE Transactions on Power Systems, Vol. PAS-89, No 7, September/October 1970, pp. 1698-1707.

- [15] Exposito A. G., Perinan P. Z., Quintana V. H., *Accurate Estimation of Circuit Breaker Positions*, LESCOPE'98. Large Engineering Systems Conference on Power Engineering. Conference Proceedings, Halifax, Canada, 7-9 June 1998, pp. 11-14.
- [16] Exposito A. G., de la Villa Jaen A., *Reduced substation models for generalized state estimation*, IEEE Transactions on Power Systems, Vol 16, No. 4, November 2001, pp. 839-846.
- [17] Gamm A. Z., Rozanov M. N., *Metody rešenija zadač real'nogo vremeni v èlektroènergetike*, Izdatel'stvo „Nauka”, Novosibirsk, 1991, str. 27-36.
- [18] Garcia-Lagos F., Joya G., Marin F.J., Sandoval F., *A neural topology estimator for power systems*, [w] Engineering benefits from neural networks, Edited by A. B. Bulsari, J. Fernandez de Canete, S. Kallio, Proceedings of the International Conference on Engineering Applications of Neural Networks, EANN'98, Gibraltar, June 10-12, 1998, pp. 245-252.
- [19] Garcia-Lagos F., Joya G., Marin F. J., Sandoval F., *A modular power system topology assessment based on Gaussian potential functions*, Proceedings of the IASTED International Conference Power and Energy Systems, September 19-22, 2000, Marbella, Spain, pp. 217-222.
- [20] Guangyi L., Xing W., Erkeng Y., *Fuzzy expert system for on-line topology error detection*, Proceedings of the International Conference on Electrical Engineering, ICEE'96, Beijing (Pekin), China, 12-15 August 1996, pp. 951-955.
- [21] Harris J. H., Kellie G. H., Prewett J. N., Jervis P., *Two implementation of state estimator for power system*, CIGRE Session, Paris, 25 August-2 September 1976, Paper no. 32-06.
- [22] Johansen T.A., *Identification of non-linear systems using empirical data and prior knowledge – an optimization approach*, Automatica, Vol. 32, No. 3, 1996, pp. 337-356.
- [23] Kłos A. Aitchison P., *Network solution. Theory and practice*, PWN, Warszawa, 1993
- [24] Koglin H.-J., Neisius H.- T., *Treatment of topological errors in substations*, Proceedings of the Tenth Power Systems Computation Conference, PSCC, Graz, Austria, 19-24 August 1990, p.1045-1053.
- [25] Koglin H.-J., Neisius H.- T., *A topology processor based on state estimation*, Proceedings of the 11-th Power Systems Computation Conference, PSCC, Avignon, France, 30 August-3 September 1993, pp.633-638 vol. 1.
- [26] Korbicz J., Obuchowicz A., Uciński, D., *Sztuczne sieci neuronowe. Podstawy i zastosowania*, Akademicka Oficyna Wydawnicza PLJ, Warszawa 1994.
- [27] Kremens Z., Sobierajski M., *Analiza systemów elektroenergetycznych*, WNT, Warszawa 1996.
- [28] Liseev M.S., Počecuev S.V., *Avtomatičeskoe formirovanie matematičeskich modelej èlektroènergetičeskich sistem po dannym telemektrii*, Izvestija Akademii Nauk SSSR, Ènègetika i Transport, 1983, no. 6, pp. 27-33.
- [29] Lu C. N., Teng J. H., Chang B. S., *Power system network topology error detection*, IEE Proceedings on Generation, Transmission and Distribution, Vol. 141, No. 6, November 1994, pp. 623-629.

- [30] Lugtu R. L., Hackett D. F., Liu K. C., Might D. D., *Power system state estimation: detection of topological errors*, IEEE Transactions on Power Systems, Vol. PAS-99, No. 6, Nov/Dec 1980, pp. 2406-2411.
- [31] Łukomski R., Wilkosz K., *Power system topology verification: assessment of different approaches*, Preprints of the 4-th International Conference Control of Power Systems, June 15-16, 2000, Bratislava, Slovakia, pp. 269-274.
- [32] Łukomski R., *New approach to power system topology verification*, referat zgłoszony i zaakceptowany na konferencję MEPS 2002.
- [33] Mansour A. E., Nour Eldin H. A., *Fast and robust bad data detection, identification and correction with subsequent direct recursive state estimation*, Proceedings of the 9-th Power Systems Computation Conference, PSCC, Carcass (Portugal) 1987, pp. 516-522.
- [34] Mili L., Steeno G., Dobraca F., French D., *A Robust Estimation Method for Topology Error Identification*, IEEE Transactions on Power Systems, Vol. 14, No. 4, November 1999, pp. 1469-1476.
- [35] Monticelli A., *Modeling circuit breakers in weighted least squares state estimation*, IEEE Trans. on Power Systems, Vol. 8, No. 3, pp. 1143-1149, August 1993.
- [36] Osowski S., *Sieci neuronowe do przetwarzania informacji*, Oficyna Wydawnicza Politechniki Warszawskiej, Warszawa 2000.
- [37] Parol M., Piotrowski P., Helt P., *Zastosowania metod sztucznej inteligencji w elektroenergetyce*, Oficyna Wydawnicza Politechniki Warszawskiej, Warszawa 2000.
- [38] Prais M., Bose A., *A topology that tracks network modifications over time*, IEEE Trans. on Power Systems, Vol. 3, No. 3, pp. 992-998, August 1988.
- [39] Romero D. R., Garcia J. R., *Network topology error identification in robust state estimation for power systems*, Control of Power Plants and Power Systems (SIPOWER '95). A Proceedings volume from the IFAC Symposium, Cancun, Mexico, pp. 207-212.
- [40] Rousseaux P., van Cutsem T., di Liacco T. E., *Whither dynamic state estimation*, Electrical Power and Energy Systems, vol. 12, 1990, pp. 104-116
- [41] Sasson A. M., Ehrmann S. T., Lynch P., van Slyck L. S., *Automatic power system network topology determination*, IEEE PAS-92, No. 2, March/April 1973, pp. 610-618.
- [42] Schweppe F. C., Handschin E., *Static state estimation in electric power systems*, Proc of IEEE, Vol. 62, No. 7, July 1974, pp. 972-982.
- [43] Singh H., Alvarado F. L., *Network topology determination using least absolute value state estimation*, IEEE Transactions on Power Systems, Vol. 10, No. 3, pp. 1159-1165, August 1995.
- [44] Singh N., Glavitsch H., *Detection and identification of topological errors in online power system analysis*, IEEE Transactions on Power Systems, Vol. 6, No. 1, February 1991, pp. 324-331.
- [45] Singh N., Oesch F., *Practical experience with rule-based on-line topology error detection*, IEEE Transactions on Power Systems, Vol. 9, No. 2, May 1994, pp. 841-847.
- [46] Souza J. C. S., Leite da Silva A. M., Alves da Silva A. P., *Data debugging for real-time power system monitoring based on pattern analysis*, IEEE Transactions on Power Systems vol. 11, no.3, August 1996, pp. 1592-1599.

- [47] Souza J. C .S., Leite da Silva A. M., Alves da Silva A. P., *Online topology determination and bad data suppression in power system operation using artificial neural networks*, IEEE Transactions on Power Systems vol. 13, no.3, August 1997, pp. 796-803.
- [48] Souza J. C .S., Leite da Silva A. M., Alves da Silva A. P., *Data visualisation and identification of anomalies in power system state estimation using artificial neural networks*, IEE Proceedings on Generation Transmission and Distribution, Vol. 144, No. 5, September 1997, pp. 445-455.
- [49] Steeno G. S., *Robust and Nonparametric Methods for Topology Error Identification and Voltage Calibration in Power Systems Engineering*, Dissertation, Virginia Polytechnic Institute, Virginia State University, 1999.
- [50] Tadeusiewicz R., *Sieci neuronowe*, Akademicka Oficyna Wydawnicza PLJ, Warszawa 1993.
- [51] Tian Tian, Minzhe Zhu, Boming Zhang, *An artificial neural network-based expert system for network topological error identification*, 1995 IEEE International Conference on Neural Networks Proceedings, Perth, WA, Australia, 27 Nov.-1 Dec. 1995, vol. 2, pp.882-886.
- [52] Vinod Kumar D. M., Srivastava S. C., Shah S., Mathur S., *Topology processing and static state estimation using artificial neural networks*, IEE Proceedings on Generation, Transmission and Distribution, Vol. 143, No. 1, January 1996, pp. 99-105.
- [53] Vinod Kumar D. M., Srivastava S. C., *Power system network topology processing based on artificial neural network*, Electric Machines and Power Systems, Vol. 26, No. 3, April 1998, pp. 249-263.
- [54] Wilkosz K., *Critical evaluation of methods for power system topology verification*, IEEE/KTH Stockholm Power Tech Conference, Stockholm, Sweden, June 18-22, 1995, vol. 4, pp. 152-157.
- [55] Wu F., Liu W.-H. E., *Detection of topology error by state estimation*, IEEE Transactions on Power Systems, Vol. 4, No. 1, February 1989, pp. 176-183.
- [56] Yehsakul P, Dabbaghchi D., *A topology-based algorithm for tracking network connectivity*, IEEE Trans. on Power Systems, Vol. 10, No. 1, pp. 339-346, February 1995.
- [57] Zhou S., *An approach to single- or multi-topology error identification*, Control of Power Systems and Power Plants (CPSPP), Beijing (Pekin), China, 1997, pp. 405-412.
- [58] Zhu Y., Sidhu T. S., Yang M. Y., Huo L. M., *An AI-based automatic power network topology processor*, Electric Power Systema Research, Vol. 61, 2002, pp. 57-65.
- [59] Żurada J., Barski M., Jędruch W., *Sztuczne sieci neuronowe*, PWN, Warszawa 1996.

Dodatki

Dodatek A. System testowy IEEE-14

1. Elementy systemu testowego

Rodzaj elementu	Ilość
Generatory	2
Kompensatory synchroniczne	3
Obciążenia	11
Gałęzie	20
Transformatory	3
Kondensatory bocznikowe	1
Rezystory bocznikowe	0

2. Parametry linii przesyłowych

Nr węzła pocz.	Nr węzła końcow.	R	X_L	B_C
1	2	0,01938	0,05917	0,05280
1	5	0,05403	0,22304	0,04920
2	3	0,04699	0,19797	0,04380
2	4	0,05811	0,17632	0,03740
2	5	0,05695	0,17388	0,03400
3	4	0,06701	0,17103	0,03460
4	5	0,01335	0,04211	0,01280
4	7	0,00000	0,20450	0,00000
4	9	0,00000	0,53890	0,00000
5	6	0,00000	0,23490	0,00000
6	11	0,09498	0,19890	0,00000
6	12	0,12291	0,25581	0,00000
6	13	0,06615	0,13027	0,00000
7	8	0,00000	0,17615	0,00000
7	9	0,00000	0,11001	0,00000
9	10	0,03181	0,08450	0,00000
9	14	0,12711	0,27038	0,00000
10	11	0,08205	0,19207	0,00000
12	13	0,22092	0,19988	0,00000
13	14	0,17093	0,34802	0,00000

3. Boczniki

Węzeł	Bocznik
9	0,19


4. Dane dla bazowego rozplywu mocy w systemie testowym IEEE-14

Nr węzła	Typ	Napięcie [pu]	Kąt fazowy	Generatory		Obciążenia	
				[MW]	[MVar]	[MW]	[MVar]
1	1	1,060	0,000	232,460	-26,400	0,000	0,000
2	2	1,041	-5,161	40,000	20,630	21,700	12,700
3	2	0,986	-12,613	0,000	13,910	94,200	19,000
4	3	1,017	-10,797	0,000	0,000	47,800	-8,900
5	3	1,028	-9,350	0,000	0,000	7,600	1,600
6	2	0,995	-15,325	0,000	44,370	11,200	7,500
7	3	1,010	-14,325	0,000	0,000	0,000	0,000
8	2	1,058	-15,002	0,000	30,460	0,000	0,000
9	3	0,989	-15,882	0,000	0,000	29,500	16,600
10	3	0,981	-15,972	0,000	0,000	9,000	5,800
11	3	0,984	-15,744	0,000	0,000	3,500	1,800
12	3	0,975	-16,028	0,000	0,000	6,100	1,600
13	3	0,972	-15,999	0,000	0,000	13,500	5,800
14	3	0,958	-16,667	0,000	0,000	14,900	5,000

Typy węzłów:


- 1 – węzeł bilansujący,
- 2 – węzeł generatorowy (typu *PU*),
- 3 – węzeł odbiorczy (typu *PQ*).

Moc podstawowa: $S_b = 100$ MVA




Rys. A.1. Schemat systemu testowego IEEE-14


Dodatek B. Wyniki na wyjściach wstępnych klasyfikatorów, gdy na ich wejścia podawane są wskaźniki niezbilansowania węzłów dla mocy czynnej i biernej




Rys.B.1. Wyniki na wyjściach wstępnych klasyfikatorów, gdy na ich wejścia podawane są wskaźniki niezbilansowania węzła nr 1: x – dla mocy czynnej; O – dla mocy biernej




Rys. B.2. Wyniki na wyjściach wstępnych klasyfikatorów, gdy na ich wejścia podawane są wskaźniki niezbilansowania dla węzła nr 2: x – dla mocy czynnej; O – dla mocy biernej




Rys. B.3. Wyniki na wyjściach wstępnych klasyfikatorów, gdy na ich wejścia podawane są wskaźniki niezbilansowania dla węzła nr 3: x – dla mocy czynnej; O – dla mocy biernej




Rys. B.4. Wyniki na wyjściach wstępnych klasyfikatorów, gdy na ich wejścia podawane są wskaźniki niezbilansowania dla węzła nr 4: x – dla mocy czynnej; O – dla mocy biernej




Rys. B.5. Wyniki na wyjściach wstępnych klasyfikatorów, gdy na ich wejścia podawane są wskaźniki niezbilansowania dla węzła nr 5: x – dla mocy czynnej; O – dla mocy biernej.




Rys. B.6. Wyniki na wyjściach wstępnych klasyfikatorów, gdy na ich wejścia podawane są wskaźniki niezbilansowania dla węzła nr 6: x – dla mocy czynnej; O – dla mocy biernej.




Rys. B.7. Wyniki na wyjściach wstępnych klasyfikatorów, gdy na ich wejścia podawane są wskaźniki niebilansowania dla węzła nr 7: × – dla mocy czynnej; ○ – dla mocy biernej.




Rys. B.8. Wyniki na wyjściach wstępnych klasyfikatorów, gdy na ich wejścia podawane są wskaźniki niebilansowania dla węzła nr 8: × – dla mocy czynnej; ○ – dla mocy biernej.




Rys. B.9. Wyniki na wyjściach wstępnych klasyfikatorów, gdy na ich wejścia podawane są wskaźniki niebilansowania dla węzła nr 9: × – dla mocy czynnej; O – dla mocy biernej.




Rys. B.10. Wyniki na wyjściach wstępnych klasyfikatorów, gdy na ich wejścia podawane są wskaźniki niebilansowania dla węzła nr 10: × – dla mocy czynnej; O – dla mocy biernej.




Rys. B.11. Wyniki na wyjściach wstępnych klasyfikatorów, gdy na ich wejścia podawane są wskaźniki niebilansowania dla węzła nr 11: $\times$ – dla mocy czynnej; $\bigcirc$ – dla mocy biernej.



Rys. B.12. Wyniki na wyjściach wstępnych klasyfikatorów, gdy na ich wejścia podawane są wskaźniki niebilansowania dla węzła nr 12: $\times$ – dla mocy czynnej; $\bigcirc$ – dla mocy biernej.




Rys. B.13. Wyniki na wyjściach wstępnych klasyfikatorów, gdy na ich wejścia podawane są wskaźniki niezbilansowania dla węzła nr 13: × – dla mocy czynnej; O – dla mocy biernej.




Rys. B.14. Wyniki na wyjściach wstępnych klasyfikatorów, gdy na ich wejścia podawane są wskaźniki niezbilansowania dla węzła nr 14: × – dla mocy czynnej; O – dla mocy biernej.


Dodatek C. Wyniki na wyjściach wstępnych klasyfikatorów, gdy na ich wejścia podawane są wskaźniki niezbilansowania gałęzi dla mocy czynnej i biernej




Rys. C.1. Wyniki na wyjściach wstępnych klasyfikatorów, gdy na ich wejścia podawane są wskaźniki niezbilansowania dla gałęzi nr 1: x – dla mocy czynnej; O – dla mocy biernej.




Rys. C.2. Wyniki na wyjściach wstępnych klasyfikatorów, gdy na ich wejścia podawane są wskaźniki niezbilansowania dla gałęzi nr 2: x – dla mocy czynnej; O – dla mocy biernej.




Rys. C.3. Wyniki na wyjściach wstępnych klasyfikatorów, gdy na ich wejścia podawane są wskaźniki niebilansowania dla gałęzi nr 3: × – dla mocy czynnej; O – dla mocy biernej.




Rys. C.4. Wyniki na wyjściach wstępnych klasyfikatorów, gdy na ich wejścia podawane są wskaźniki niebilansowania dla gałęzi nr 4: × – dla mocy czynnej; O – dla mocy biernej.




Rys. C.5. Wyniki na wyjściach wstępnych klasyfikatorów, gdy na ich wejścia podawane są wskaźniki niebilansowania dla gałęzi nr 5: × – dla mocy czynnej; O – dla mocy biernej.




Rys. C.6. Wyniki na wyjściach wstępnych klasyfikatorów, gdy na ich wejścia podawane są wskaźniki niebilansowania dla gałęzi nr 6: × – dla mocy czynnej; O – dla mocy biernej.




Rys. C.7. Wyniki na wyjściach wstępnych klasyfikatorów, gdy na ich wejścia podawane są wskaźniki niezbilansowania dla gałęzi nr 7: × – dla mocy czynnej; O – dla mocy biernej.




Rys. C.8. Wyniki na wyjściach wstępnych klasyfikatorów, gdy na ich wejścia podawane są wskaźniki niezbilansowania dla gałęzi nr 8: × – dla mocy czynnej; O – dla mocy biernej.




Rys. C.9. Wyniki na wyjściach wstępnych klasyfikatorów, gdy na ich wejścia podawane są wskaźniki niebilansowania dla gałęzi nr 9: x – dla mocy czynnej; O – dla mocy biernej.




Rys. C.10. Wyniki na wyjściach wstępnych klasyfikatorów, gdy na ich wejścia podawane są wskaźniki niebilansowania dla gałęzi nr 10: x – dla mocy czynnej; O – dla mocy biernej.




Rys. C.11. Wyniki na wyjściach wstępnych klasyfikatorów, gdy na ich wejścia podawane są wskaźniki niezbilansowania dla gałęzi nr 11: × – dla mocy czynnej; O – dla mocy biernej.




Rys. C.12. Wyniki na wyjściach wstępnych klasyfikatorów, gdy na ich wejścia podawane są wskaźniki niezbilansowania dla gałęzi nr 12: × – dla mocy czynnej; O – dla mocy biernej.




Rys. C.13. Wyniki na wyjściach wstępnych klasyfikatorów, gdy na ich wejścia podawane są wskaźniki niezbilansowania dla gałęzi nr 13: × – dla mocy czynnej; O – dla mocy biernej.




Rys. C.14. Wyniki na wyjściach wstępnych klasyfikatorów, gdy na ich wejścia podawane są wskaźniki niezbilansowania dla gałęzi nr 14: × – dla mocy czynnej; O – dla mocy biernej.




Rys. C.15. Wyniki na wyjściach wstępnych klasyfikatorów, gdy na ich wejścia podawane są wskaźniki niezbilansowania dla gałęzi nr 15: x – dla mocy czynnej; O – dla mocy biernej.




Rys. C.16. Wyniki na wyjściach wstępnych klasyfikatorów, gdy na ich wejścia podawane są wskaźniki niezbilansowania dla gałęzi nr 16: x – dla mocy czynnej; O – dla mocy biernej.




Rys. C.17. Wyniki na wyjściach wstępnych klasyfikatorów, gdy na ich wejścia podawane są wskaźniki niebilansowania dla gałęzi nr 17: × – dla mocy czynnej; O – dla mocy biernej.



Rys. C.18. Wyniki na wyjściach wstępnych klasyfikatorów, gdy na ich wejścia podawane są wskaźniki niebilansowania dla gałęzi nr 18: × – dla mocy czynnej; O – dla mocy biernej.




Rys. C.19. Wyniki na wyjściach wstępnych klasyfikatorów, gdy na ich wejścia podawane są wskaźniki niezbilansowania dla gałęzi nr 19: × – dla mocy czynnej; O – dla mocy biernej.




Rys. C.20. Wyniki na wyjściach wstępnych klasyfikatorów, gdy na ich wejścia podawane są wskaźniki niezbilansowania dla gałęzi nr 20: × – dla mocy czynnej; O – dla mocy biernej.


Dodatek D. Uczenie sztucznych sieci neuronowych




Rys. D.1. Błąd średniokwadratowy uczenia w poszczególnych epokach dla sieci neuronowej klasyfikatora lokalnego skojarzonego z węzłem nr 1.




Rys. D.2. Błąd średniokwadratowy uczenia w poszczególnych epokach dla sieci neuronowej klasyfikatora lokalnego skojarzonego z węzłem nr 2.




Rys. D.3. Błąd średniokwadratowy uczenia w poszczególnych epokach dla sieci neuronowej klasyfikatora lokalnego skojarzonego z węzłem nr 3.




Rys. D.4. Błąd średniokwadratowy uczenia w poszczególnych epokach dla sieci neuronowej klasyfikatora lokalnego skojarzonego z węzłem nr 4.




Rys. D.5. Błąd średniokwadratowy uczenia w poszczególnych epokach dla sieci neuronowej klasyfikatora lokalnego skojarzonego z węzłem nr 5.




Rys. D.6. Błąd średniokwadratowy uczenia w poszczególnych epokach dla sieci neuronowej klasyfikatora lokalnego skojarzonego z węzłem nr 6.




Rys. D.7. Błąd średniokwadratowy uczenia w poszczególnych epokach dla sieci neuronowej klasyfikatora lokalnego skojarzonego z węzłem nr 7.




Rys. D.8. Błąd średniokwadratowy uczenia w poszczególnych epokach dla sieci neuronowej klasyfikatora lokalnego skojarzonego z węzłem nr 8.




Rys. D.9. Błąd średniokwadratowy uczenia w poszczególnych epokach dla sieci neuronowej klasyfikatora lokalnego skojarzonego z węzłem nr 9.




Rys. D.10. Błąd średniokwadratowy uczenia w poszczególnych epokach dla sieci neuronowej klasyfikatora lokalnego skojarzonego z węzłem nr 10.




Rys. D.11. Błąd średniokwadratowy uczenia w poszczególnych epokach dla sieci neuronowej klasyfikatora lokalnego skojarzonego z węzłem nr 11.



Rys. D.12. Błąd średniokwadratowy uczenia w poszczególnych epokach dla sieci neuronowej klasyfikatora lokalnego skojarzonego z węzłem nr 12.



Rys. D.13. Błąd średniokwadratowy uczenia w poszczególnych epokach dla sieci neuronowej klasyfikatora lokalnego skojarzonego z węzłem nr 13.



Rys. D.14. Błąd średniokwadratowy uczenia w poszczególnych epokach dla sieci neuronowej klasyfikatora lokalnego skojarzonego z węzłem nr 14.

