

Koordynator: Waldemar SKOMUDEK

Jerzy DZIEŻA (1), Aleksander LORENC (4), Jerzy RYDLEWSKI (5), Anna SERWATKA (3),
Waldemar SKOMUDEK (2)

XII. Ekonomiczna efektywność przedsięwzięć inwestycyjnych w energetyce opartej na zasadach rynkowych w warunkach transformacji sektorowej

Abstrakt: Nadrzędnym celem rozwojowym przedsiębiorstw energetycznych funkcjonujących w warunkach konkurencyjnego rynku energii jest dążenie do wzrostu ich wartości poprzez realizację zamierzeń inwestycyjnych o charakterze rozwojowym, ekonomicznie efektywnych i gwarantujących bezpieczeństwo pracy systemu elektroenergetycznego. Przyjęcie takiej perspektywy przesądza o tym, że w ciągu najbliższej dekady powinny być realizowane głównie zamierzenia o dużym stopniu innowacyjności, usprawniające niemal wszystkie procesy biznesowe. Oznacza to również, że podejmowanie decyzji inwestycyjnych powinno bazować na gruntownej i rzetelnej ocenie ich opłacalności i efektywności, a także uwzględniać zmianę wartości pieniądza w czasie, ryzyko traktowane jako obiektywnie istniejąca możliwość niepowodzenia w realizacji zamierzonych celów inwestycyjnych oraz realny okres trwania inwestycji. Dla tak określonego obszaru zagadnień w artykule zaprezentowano informacje z zakresu wyznaczania efektywności energetycznych projektów inwestycyjnych, określania optymalnych modeli ich finansowania, kształtowania przychodu regulowanego operatorów sieci elektroenergetycznych oraz monitorowania uzyskanych rezultatów w odniesieniu do poniesionych nakładów inwestycyjnych, zastosowania innowacyjnych metod modelowania agentowego i teorii grafów, a także metody analizy wielowymiarowej oraz metody teorii gier stosowane do wyceny energetycznych projektów inwestycyjnych.

Słowa kluczowe: ekonomiczna efektywność inwestycji, finansowanie inwestycji, stabilność pracy KSE, modelowanie agentowe, wycena opcji

Współczesny krajowy sektor energetyczny przechodzi dynamiczne przemiany, które wynikają zarówno z założeń polityki klimatyczno-energetycznej Unii Europejskiej i presji regulacyjnej, jak i z postępu technologicznego oraz zmieniających się oczekiwań społecznych i ekonomicznych. Transformacja energetyczna (TE), której fundamentem są dekarbonizacja, decentralizacja i digitalizacja, stawia przed inwestorami, operatorami sieci elektroenergetycznych oraz decydentami zarządzającymi wielkoskalową energetyką

konwencjonalną nowe wyzwania w zakresie planowania, analizy i oceny potrzeb energetycznych kraju oraz finansowania zamierzeń inwestycyjnych, niezbędnych z punktu widzenia sektora. Wymaga to nie tylko głębokiego rozumienia aspektów technicznych, organizacyjno-prawnych i rynkowych, ale również umiejętności stosowania zaawansowanych narzędzi analitycznych i finansowych, umożliwiających tworzenie interaktywnych prognoz, raportów i symulacji efektywności podejmowanych działań rozwojowych. Zachowując otwarte podejście do procesu przebudowy krajowej energetyki, sprzyjamy osiągnięciu nadrzędnego celu polityki energetycznej, którym jest bezpieczeństwo energetyczne gwarantujące zapewnienie konkurencyjności gospodarki, efektywności energetycznej i obniżenie oddziaływania sektora energii na środowisko. Jednocześnie osiągnięcie celu powinno nastąpić przy zachowaniu optymalnego wykorzystania własnych zasobów energetycznych oraz zachowaniu racjonalności alokacji środków finansowych w przyszłe aktywa energetyczne.

W niniejszym artykule składającym się z kilku merytorycznie powiązanych opracowań podjęto próbę zaprezentowania kompleksowego i innowacyjnego podejścia do oceny ekonomicznej efektywności przedsięwzięć inwestycyjnych w energetyce z perspektywy interdyscyplinarnej, łączącej wiedzę z zakresu energetyki, ekonomii oraz matematyki stosowanej. W kolejnych fragmentach rozdziału omówiono metody oceny

efektywności inwestycyjnej, zarówno klasyczne (statyczne – nieuwzględniające zmiany wartości pieniądza w czasie, i dynamiczne – uwzględniające wpływ czasu i ryzyka na wynik inwestycji), jak i bardziej zaawansowane, oparte na dyskontowaniu przepływów pieniężnych z uwzględnieniem ryzyka rynkowego i niestabilności cen energii. Szczególną uwagę zwrócono na wykorzystanie narzędzi matematyki finansowej, w tym na zastosowanie rachunku prawdopodobieństwa, procesów stochastycznych oraz statystyki matematycznej, umożliwiających modelowanie niepewności w decyzjach finansowych, analizę cen aktywów finansowych i zarządzania ich portfelem. Zaprezentowano także metodę wyceny instrumentów pochodnych (opcji *spread*), które pozwalają modelować strategie zabezpieczające przed wahaniami cen energii elektrycznej na rynkach hurtowych.

Wśród zebranych opracowań znajduje się publikacja opisująca innowacyjne modelowanie zachowań uczestników rynku energii wykorzystujące podejście agentowe. Dzięki modelom opartym na agentach możliwe jest realistyczne odwzorowanie decyzji inwestorów, prosumentów, operatorów systemu dystrybucyjnego i innych beneficjentów rynku energii, z uwzględnieniem ich indywidualnych profili zużycia energii, strategii magazynowania oraz zagospodarowywania nadwyżek energii elektrycznej (np. poprzez sprzedaż na rynku lub wykorzystanie lokalne). Pozwala to na ocenę skutków ekonomicznych różnych wariantów inwestycyjnych w warunkach niepewności i zmiennego otoczenia regulacyjnego.

W dalszej części artykułu znajdują się opracowania dotyczące możliwości zastosowania teorii gier jako narzędzia do oceny optymalnych strategii współpracy i konkurencji między uczestnikami rynku, przy realizacji wspólnych inwestycji infrastrukturalnych. Wyniki badań w tym zakresie potwierdzają słuszność rozwijania metod statystycznych, które umożliwiają dokonywanie rozsądnej wyceny energetycznych projektów inwestycyjnych.

Następnie zamieszczono opracowanie nawiązujące do mechanizmu kształtowania przychodu regulowanego operatorów systemu dystrybucyjnego,

będącego narzędziem oddziaływania regulatora na wynik finansowy spółek operatorskich. Omówiono ogólne zasady kalkulacji taryf, uwzględniając podstawowe parametry finansowych analiz opłacalności inwestycji, takich jak: zwrot z kapitału, koszty operacyjne, opłaty przejściowe oraz mechanizmy zachęt inwestycyjnych. W opracowaniu zawarto również propozycję zastosowania wskaźnika efektywności alokacji nakładów inwestycyjnych jako miernika efektów transformacji energetycznej.

W końcowej części artykułu znajduje się ogólne podsumowanie aplikacyjnego charakteru zamieszczonych opracowań, które – poza wartością naukową – potwierdzają słuszność stosowania w energetyce nowych technologii oraz innowacyjnych metod analizy i oceny ich efektywności. Mają one również na celu dostarczenie narzędzi do racjonalnej oceny projektów inwestycyjnych oraz pobudzenie debaty nad potrzebą szerszego stosowania interdyscyplinarnego podejścia do analiz w sektorze energii, który odgrywa kluczową rolę w rozwoju gospodarczym i w transformacji klimatyczno-energetycznej kraju.

1. Wyznaczanie efektywności projektów inwestycyjnych w energetyce


Zarówno nowe technologie generacji energii elektrycznej, jak i postępujące zmiany podstawowego modelu rynku energii, stawiają wyzwania dla całego sektora energetycznego. W przypadku tradycyjnego, regulowanego rynku energii elektrycznej jedynym źródłem ryzyka dla wytwórców była aktualna wielkość popytu oraz możliwość wystąpienia awarii technicznej. W takim modelu ryzyko działalności było ograniczone do czynnika operacyjnego, szczególnie do sytuacji, w której popyt przewyższał podaż energii. Wraz z liberalizacją rynku energii i wprowadzeniem giełdy energii główne cele uczestników rynku uległy zasadniczej zmianie. Obecnie ryzyko ma naturę nie tylko fizyczną (np. w postaci ewentualnego niedopasowania podaży i popytu), ale także finansową – jest

związane z losowym charakterem ceny energii elektrycznej i paliwa (Eydeland et Wolyniec 2003).

Najbardziej widoczną konsekwencją liberalizacji rynku energii jest duża zmienność ceny na rynku hurtowym (zarówno *spot*, jak i *forward*), w przeciwieństwie do stałej ceny, która była ustalana urzędowo. Co więcej, gdy zliberalizowano również rynki węgla i gazu (paliwa jednostek generacyjnych), to koszty wytwarzania energii zaczęły przybierać losowe wartości. Dodatkowo, jeśli elektrownia emituje dwutlenek węgla, to kosztem stają się również certyfikaty emisyjne. Z kolei w przypadku OZE źródłami niepewności mogą być warunki atmosferyczne, takie jak siła wiatru dla farm wiatrowych czy poziom nasłonecznienia dla generacji fotowoltaicznej.

Klasycznym pomysłem na zarządzanie ryzykiem cenowym energii elektrycznej, paliwa i certyfikatu emisyjnego jest *clean spread*¹. *Spread* określa w przybliżeniu koszt konwersji energii jednego rodzaju (paliwa) na inny rodzaj (energię elektryczną), a *clean spread* obejmuje dodatkowo koszty emisji CO₂. Jeśli uwzględnić elastyczność w podejmowaniu decyzji, to **operator bloku energetycznego** ma długą pozycję

w opcji kupna na *clean spread*. Z kolei dla generacji z OZE operator będzie miał długą pozycję w opcji kupna na *green spread*. W obu przypadkach *spread* odgrywa kluczową rolę przy podejmowaniu decyzji inwestycyjnych. W polskiej literaturze przedmiotu dotyczącej zarządzania ryzykiem cenowym energii lub otwartą pozycją operatora elektrowni trudno znaleźć prace dotyczące mechanizmu spreadu, a tym bardziej *clean/green spreadu*, nie wspominając już o opcji „na spread” używanej w spekulacji, zarządzaniu ryzykiem cenowym oraz w wycenie fizycznych aktywów energetycznych. Spread jest przykładem opcji korelacyjnych, w których wypłata zależy od powiązań pomiędzy cenami (stopami zwrotu) instrumentów bazowych. Niektórzy rozważają również kointegrację odpowiednich szeregów czasowych, co pozwala na statystyczny arbitraż (Hendricks et Ehrhardt 2013). *Spread* wyznacza też krzywą podaży energii elektrycznej na rynku (*merit order*). Blok energetyczny, który ma w danej chwili najwyższy *spread*, najszybciej wchodzi do produkcji. Stąd generacja z OZE, oprócz uwarunkowań prawnych, ma priorytet na krzywej podaży (Rys. 1).



Rys. 1. Krzywa podaży (*merit order*) w generacji energii elektrycznej

¹ Według stanu wiedzy autora, praktycy używają pojęć anglojęzycznych i w pracy też będzie użyta taka konwencja.

Traktując *spread* jako kluczową wielkość związaną z kosztem generacji energii elektrycznej, można przedstawić następujące podstawowe kryteria podejmowania decyzji inwestycyjnych w energetyce: wartość bieżąca netto NPV, wewnętrzna stopa zwrotu IRR, uśredniony koszt energii elektrycznej LCOE, a także wybrane alternatywne wskaźniki dla LCOE.

Wartość bieżąca netto NPV (*net present value*) jest najczęściej stosowanym kryterium inwestycyjnym określonym zależnością:

$$NPV(0) = -I + \sum_{i=1}^T \frac{E(CF(i))}{(1+k)^i} \quad (1)$$

gdzie:

$CF(i)$ – przepływ pieniężny z projektu w i -tym roku,

$E()$ – operator wartości oczekiwanej,

k – koszt kapitału projektu,

T – czas życia projektu.

Przyjmuje się, że projekt powinien być realizowany, jeśli wartość bieżąca netto jest dodatnia. Pomimo prostoty tego kryterium istnieją jednak poważne ograniczenia w jego praktycznym stosowaniu, ze względu na trudności w określeniu takich czynników jak:

- przyszłe przepływy pieniężne $CF(i)$ projektu – stąd wartość oczekiwana,
- miara probabilistyczna do wyznaczenia wartości oczekiwanej,
- koszt kapitału k projektu.

Jeśli przepływy pieniężne zależałyby tylko od innych instrumentów finansowych będących w publicznym obrocie, co oznaczałoby, że można byłoby je replikować, to zgodnie z twierdzeniem o wycenie aktywów kapitałowych można by zastosować miarę neutralną względem ryzyka (Duffie 2001). Jednak inwestycje kapitałowe dotyczą niefinansowych instrumentów, dla których, w ogólności, pewne ryzyka nie mają ceny rynkowej. Tak jest właśnie w przypadku generacji energii elektrycznej. Rynek jest niezupełny i nie sposób zdefiniować jedynej miary martyngałowej (miara neutralna względem ryzyka) pozwalającej

wycenić analizowane instrumenty finansowe. W praktyce ryzyko projektu jest szacowane poprzez dobranie odpowiedniej stopy dyskontowej (*risk adjusted discount rate*) (Graham et Harvey 2021). Aby znaleźć stopę dyskontową dostosowaną do ryzyka związanego z projektem, przy podejmowaniu decyzji inwestycyjnej należy zatem odwołać się do kosztu kapitału własnego i obcego, które finansują projekt. Stąd identyfikacja dostosowanej do ryzyka stopy dyskontowej projektu związana jest z wyznaczeniem średniego ważonego kosztu kapitału WACC (*weighted average cost of capital*), według wzoru:

$$WACC = \frac{D}{D+E} k_D (1 - \tau_c) + \frac{E}{D+E} k_E \quad (2)$$

gdzie:

D – wartość kapitału obcego,

E – wartość kapitału własnego,

τ_c – wysokość stopy podatkowej,

k_D – koszt kapitału obcego,

k_E – koszt kapitału własnego.

W zależności (2) pojawia się koszt kapitału własnego k_E – parametr, który trudno wyznaczyć w rzeczywistości. Parametr ten jest wielkością nieobserwowalną bezpośrednio na rynku i jego estymacja odwołuje się do idei równowagi rynków finansowych. Oznacza to, że inwestorzy powinni oczekiwać takiej stopy zwrotu z inwestycji, która rekompensuje ryzyko projektu. Najbardziej znanym modelem równowagi jest *capital asset pricing model* (CAPM), w którym inwestor jest nagradzany za podjęcie ryzyka systematycznego projektu, czyli takiego, które nie może być osłonięte dobrze zdywersyfikowanym portfelem innych instrumentów finansowych. Prostota modelu CAPM powoduje, że jest on preferowanym narzędziem zarządczym, pomimo ograniczonych możliwości w prognozowaniu oczekiwanych stóp zwrotu na rynku akcji (Fama et French 1992, 2004). Celem zarządzającego projektem (firmą) jest maksymalizacja jego (jej) wartości. Aby osiągnąć ten cel, należy minimalizować średni ważony koszt kapitału projektu. W związku z tym powinno się dążyć do optymalnej struktury kapitałowej firmy.

Wewnętrzna stopa zwrotu IRR (*internal rate of return*) to kryterium podejmowania decyzji inwestycyjnych, które określa taki koszt kapitału, dla którego NPV projektu wynosi 0. Wartość tego parametru można wyliczyć z równania:

$$0 = -I + \frac{E(CF(1))}{(1+IRR)} + \frac{E(CF(2))}{(1+IRR)^2} + \dots + \frac{E(CF(T))}{(1+IRR)^T} \quad (3)$$

Zgodnie z zależnością (3), projekt podlega realizacji, jeśli IRR jest większa niż koszt kapitału projektu k . To kryterium jest często stosowane, pomimo że stopa IRR nie ma ekonomicznego uzasadnienia, bo jest rozwiązaniem równania (3). Zależność (3) może mieć również wiele rozwiązań, co dodatkowo wywołuje trudności interpretacyjne.

Uśredniony koszt energii elektrycznej LCOE (*levelized cost of electricity*) to miara podejmowania decyzji inwestycyjnych polegająca na uzyskaniu informacji, jaka powinna być średnia cena energii elektrycznej S_{av} , aby inwestycja w określoną technologię generacji była opłacalna. Przykładowo, dla generacji węglowej średnią cenę energii elektrycznej można określić, korzystając z następującego wzoru:

$$0 = -I + \sum_{i=1}^T \frac{N(S_{av} - H_c S_c - I_c S_{CO_2}) - K_s}{(1+k)^i} \quad (4)$$

gdzie:

N – liczba godzin pracy bloku/elektrowni w ciągu roku,

S_{av} – średnia cena energii elektrycznej [PLN/MWh],

S_c – średnia cena węgla kamiennego [PLN/GJ],

H_c – współczynnik konwersji węgla kamiennego [GJ/MWh],

S_{CO_2} – średnia cena certyfikatu [PLN/MWh],

I_c – wskaźnik intensywności emisji węgla kamiennego [tCO₂/MWh],

k – koszt kapitału projektu,

K_s – jednostkowe (roczne) koszty stałe [PLN].

Za pomocą zależności (4) można określić, jaka powinna być uśredniona cena energii elektrycznej S_{av} , aby NPV projektu było równe 0 (punkt opłacalności

projektu). Przywołane działanie jest zbieżne z określeniem wewnętrznej stopy zwrotu IRR, przy czym w rozważanym przypadku poszukiwana jest stosowna cena energii elektrycznej S_{av} , a nie koszt kapitału, jak w metodzie liczenia IRR. Wyznaczając średnią cenę energii S_{av} z zależności (4), uzyskuje się wzór:

$$S_{av} = H_c S_c + I_c S_{CO_2} + \frac{K_s}{N} + \frac{I}{N} \frac{1-b}{b(1-b^T)} \quad (5)$$

gdzie parametr $b = 1/(1+k)$.

W przypadku generacji odnawialnej w zależności (4) zamiast *clean dark spread* należy wziąć pod uwagę *green spread*, co prowadzi do zależności:

$$0 = -I + \sum_{i=1}^T \frac{N(S_{av} - S_{REC}) - K_s}{(1+k)^i} \quad (6)$$

Stąd średnia cena energii elektrycznej dla generacji odnawialnej wynosi:

$$S_{av} = -S_{REC} + \frac{K_s}{N} + \frac{I}{N} \frac{1-b}{b(1-b^T)} \quad (7)$$

Szczególne cechy energii elektrycznej powodują, że podejmowanie inwestycji związanych z generacją energii jest szczególnie trudne. Klasyczne wskaźniki podejmowania decyzji inwestycyjnych polegają na porównaniu wartości bieżącej kosztów projektu z wartościami bieżącymi przyszłych przychodów. Jeśli ich wartość bieżąca jest wyższa niż wartość bieżąca kosztów, to kryterium inwestycyjne potwierdza zasadność realizacji projektu.

Wskaźnik LCOE jest klasyczną miarą pozwalającą porównać koszty wytworzenia energii elektrycznej przez różne systemy generacji, jednak – jak pokazano wcześniej – nie uwzględnia wielu czynników w projektowaniu współczesnego systemu elektroenergetycznego. Literatura przedmiotu proponuje kilka alternatywnych rozwiązań dla wskaźnika LCOE:

- skorygowana wartość uśrednionego kosztu energii elektrycznej (*value-adjusted levelized cost of electricity* – VALCOE),

- systemowy uśredniony koszt energii elektrycznej (*system levelized cost of electricity* – sLCOE),
- uśredniony całkowity system kosztów energii elektrycznej (*levelized full system costs of electricity* – LFSCOE),
- koszt dostawy energii elektrycznej w zależności od obciążenia (*load-following supply cost of electricity* – LFSCOE),
- uśredniony (uniknięty) koszt energii elektrycznej (*levelized avoided cost of electricity* – LACE).

Tradycyjne metody wyceny projektów inwestycyjnych poprzez analizę zdyskontowanych przepływów pieniężnych powinny prowadzić do maksymalizacji wartości bieżącej netto NPV. Takie podejście oznacza, że przepływy pieniężne muszą mieć określoną sztywną (nieelastyczną) ścieżkę, co powoduje, że zarządzający projektem nie mogą reagować na pojawiające się w trakcie jego realizacji nowe niepewności.

Pomimo prostego i jasnego kryterium podejmowania decyzji inwestycyjnych, które jest stosowane przez firmy od wielu lat, statyczność metody NPV i IRR powoduje, że w wycenie energetycznego projektu inwestycyjnego pomijana jest możliwość reakcji osób zarządzających na zmieniające się otoczenie biznesowe (Boer 2000, Brealey et Myers 2000).

Rzeczywistość rynkowa pokazuje, że działanie firmy w sektorze energetycznym charakteryzuje się dynamicznymi zmianami otoczenia, niespodziewanymi zmianami warunków atmosferycznych, niepewnością oraz oddziaływaniem konkurencji, co często oznacza, że przepływy pieniężne z projektu (lub ich rozkład) różnią się znacznie od pierwotnie przyjętych założeń. Informacje napływające w czasie realizacji projektu i zmniejszająca się niepewność wobec przyszłych przepływów pieniężnych pozwalają zarządzającym na bieżące dokonywanie zmian, takich jak opóźnienie realizacji pewnej fazy projektu, rozszerzenie lub zmniejszenie jego skali czy rozpoczęcie realizacji kolejnego projektu (Dixit et Pindyck 1994).

Zdecydowana większość energetycznych projektów inwestycyjnych charakteryzuje się następującymi właściwościami:

- nieodwracalność poniesionych nakładów inwestycyjnych,
- niepewność dotycząca przyszłych przepływów pieniężnych z projektu,
- możliwość optymalizowania chwili podjęcia projektu.

Te czynniki powodują, że klasyczne metody oceny ekonomicznej projektów inwestycyjnych pozostawiają wiele do życzenia. Warto zatem szukać elastyczności w pracy wytwórcy energii elektrycznej, a co za tym idzie – stosować narzędzia opcji realnych w wycenie projektu.

2. Zasady kształtowania przychodu regulowanego operatorów sieci dystrybucyjnej oraz monitorowanie uzyskanych efektów alokacji nakładów inwestycyjnych

System elektroenergetyczny – postrzegany jako zespół wzajemnie połączonych i współpracujących urządzeń przeznaczonych do wytwarzania, przesyłania, rozdziału i przetwarzania energii elektrycznej na inne formy energii – powinien spełniać wymagania o charakterze technicznym i ekonomicznym, utrzymywać wysoką jakość energii, niezawodność zasilania odbiorców oraz niskie koszty utrzymania, a także wykazywać wysoką efektywność działań modernizacyjnych i rozwojowych, i gwarantować skuteczność operacyjnego zarządzania siecią oraz bezpieczeństwo pracy obsługi i użytkowników (Ustawa z dnia 10 kwietnia 1997 r. Prawo energetyczne).

Obecnie w opisie zagadnień funkcjonowania Krajowego Systemu Elektroenergetycznego (KSE) dużo uwagi poświęca się standardom jakości energii dostarczanej odbiorcom. Rola pewności i ciągłości

dostaw nabiera znaczenia w miarę wzrostu stopnia skomplikowania procesów produkcyjnych, z reguły sterowanych automatycznie z wykorzystaniem techniki cyfrowej. Zmusza to operatorów sieci elektroenergetycznych do stosowania rozwiązań technicznych i organizacyjnych, które wpływają na obniżenie wskaźnika awaryjności systemu elektroenergetycznego i jego elementów składowych. W obszarze KSE dynamicznie rozwija się także energetyka rozproszona i prosumencka bazująca na innowacyjnych rozwiązaniach kogeneracyjnych (np. układy gazowo-parowe dwupaliwowe, systemy trigeneracyjne), odnawialnych źródłach energii i jej magazynowaniu. Wskazane kierunki rozwoju sektora wymagają zatem prowadzenia efektywnych i optymalnych rynkowo analiz techniczno-ekonomicznych służących tworzeniu właściwej strategii inwestycyjnej w generacji, akumulacji i przesyłaniu energii elektrycznej i ciepła, a także w zakresie skutecznego zarządzania wytworzoną energią, w szczególności w okresach jej nadmiaru w systemie.

Działalność naukowo-badawcza, odpowiadająca na potrzebę tworzenia energetyki akceptowalnej ekonomicznie i zapewniającej bezpieczeństwo, koncentruje się w znacznym stopniu na metodach zapewniających jak najwyższą efektywność wytwarzania, magazynowania i przesyłania energii elektrycznej. Do realizacji tych celów wykorzystywane są autorskie, innowacyjne procedury badawcze modeli i rzeczywistych obiektów elektroenergetycznych, a także metody obiektywizacji wyników pomiarów sygnałów elektrycznych i/lub zebranych danych. Można tego dokonać poprzez zastosowanie cyfrowej dekompozycji zbiorów danych, symulacji komputerowych (kalkulatory opłacalności rynkowej w obszarach technicznego i handlowego bilansowania systemu), a także modeli matematycznych z czasem ciągłym, umożliwiających wyznaczenie optymalnej strategii inwestycyjnej, gwarantującej stabilność pracy KSE. Rezultaty działalności naukowo-badawczej każdorazowo podlegają weryfikacji w celu potwierdzenia osiągnięcia pożądanego efektu.

W dalszej części opracowania przedstawiono propozycję zastosowania metody parametrycznej

oceny efektywności alokacji nakładów inwestycyjnych jako miernika uzyskiwanych efektów transformacyjnych. Głównym źródłem pozyskania środków finansowych na realizację potrzeb inwestycyjnych operatorów dystrybucyjnych jest taryfa opracowana na podstawie założeń Urzędu Regulacji Energetyki (2021, 2022a, 2024; Buk 2018). Kalkulacja taryf dla działalności związanej z dystrybucją energii elektrycznej zasadniczo bazuje na modelu oceny kosztów operacyjnych oraz różnicy bilansowej, a także na ustalaniu wartości regulacyjnej aktywów i zwrotu z zaangażowanego kapitału, w obliczaniu których istotną rolę odgrywa średnioważony koszt kapitału (Urząd Regulacji Energetyki 2021, 2022a, 2024). Uproszczone modele kalkulacji przychodu regulowanego oraz finansowania wydatków kapitałowych związanych bezpośrednio z budową nowej lub modernizacją istniejącej infrastruktury sieciowej – CAPEX zaprezentowano poniżej.

Kalkulacja przychodu regulowanego – Taryfa OSD

- | | | |
|---|---|-----------------------|
| <ul style="list-style-type: none"> • (+) Amortyzacja, jako pochodna CAPEX-u • (+) Zwrot z zaangażowanego kapitału (WACC) • (+) Koszty ponoszone na rzecz OSP i OSD • (+) Koszty zakupu energii na pokrycie różnicy bilansowej • (+) Koszty operacyjne OSD, w tym podatki | } | = Przychód regulowany |
|---|---|-----------------------|

Uproszczony model finansowania CAPEX-u

- (+) Amortyzacja, jako pochodna CAPEX-u
- (+) Zwrot z zaangażowanego kapitału (WACC)
- (+) Opłaty przyłączeniowe jako pochodna CAPEX-u
- (+) Dotacje
- (–) Koszty finansowe od zaciągniętych pożyczek, kredytów
- (–) Podatek CIT (19 %)

Z analizy wpływu wartości średnioważonego kosztu kapitału (WACC) na finansowanie wydatków

inwestycyjnych OSD wynika, że aby zrealizować pełny zakres zidentyfikowanych potrzeb sieciowych (Urząd Regulacji Energetyki 2022b, Ministerstwo Klimatu i Środowiska 2021, Ministerstwo Aktywów Państwowych 2019, Ustawa z dnia 7 lipca 2023 r.) wskaźnik ten, średnioważony wartością regulacyjną aktywów (WRA), powinien wynosić ok. 13%. Dla porównania, w taryfie z roku 2025 przyjęto WACC na poziomie 8,478%. Widać zatem, jak istotne jest właściwe określenie wartości tego wskaźnika. Z jednej strony należy wziąć przy tym pod uwagę realizację prawidłowo i rzetelnie zidentyfikowanych potrzeb sieciowych, a z drugiej strony trzeba zachować dbałość o utrzymanie stawek opłat taryfowych na społecznie akceptowalnym poziomie.

Biorąc pod uwagę istotność wartości wskaźnika WACC w procesie pozyskania środków inwestycyjnych na realizację celów transformacji elektroenergetyki, za właściwe należy przyjąć działanie zmierzające do wprowadzenia dodatkowego narzędzia monitorującego uzyskanie efektów transformacji sieciowej. Na podstawie przeprowadzonych prac analitycznych, a także przy uwzględnieniu założeń URE dotyczących taryfowania działalności OSD, można zaproponować określenie wartości wskaźnika efektywności alokacji nakładów inwestycyjnych E_{ANI} według jednej z kilku zaproponowanych zależności:

$$E_{ANI} = (I_{t(AI)} + I_{t(BI)}) / [WRA_{(t)} - WRA_{(t-1)}] \quad (8)$$

lub

$$E_{ANI} = [(WRA_{(t; AI)} + WRA_{(t; BI)}) - (WRA_{(t-1; AI)} + WRA_{(t-1; BI)})] / [WRA_{(t)} - WRA_{(t-1)}] \quad (9)$$

lub

$$E_{ANI} = \Delta WRA / \Delta P_{przył} \text{ (w mln zł/MW)} \quad (10)$$

lub

$$E_{ANI} = (I_{t(AI)} + I_{t(BI)}) / \Delta P_{przył} \text{ (w mln zł/MW)} \quad (11)$$

lub

$$E_{ANI} = (I_{t(AI)} + I_{t(BI)}) / I_t \quad (12)$$

Objaśnienia do wzorów (8)–(12):

E_{ANI} – wskaźnik efektywności alokacji nakładów inwestycyjnych; odniesienie nakładów inwestycyjnych roku t (zaangażowanych w zadania służące tworzeniu potencjału dla przyłączania nowych klientów, wzrostu zapotrzebowania na moc przyłączeniową u klientów istniejących, przyłączania do sieci OZE oraz punktów ładowania samochodów elektrycznych i in.) do przyrostu wartości regulacyjnej aktywów w roku t ; wartość wskaźnika mieści się w przedziale od 0 do 1;

WRA – wartość regulacyjna środków trwałych faktycznie zaangażowanych w prowadzenie działalności koncesjonowanej, ustalona na podstawie wartości księgowej, z uwzględnieniem planowanych nakładów inwestycyjnych w infrastrukturę dystrybucyjną [mln zł];

$WRA_{(t)}$ – wartość regulacyjna aktywów w roku t [mln zł];

$WRA_{(t-1)}$ – wartość regulacyjna aktywów w roku $t-1$ [mln zł];

$I_{t(AI)}$ – wartość nakładów inwestycyjnych poniesiona w roku t w grupie zadań – przyłączenia nowych odbiorców i nowych źródeł oraz związana z tym budowa nowych sieci [mln zł];

$I_{t(BI)}$ – wartość nakładów inwestycyjnych poniesiona w roku t w grupie zadań – modernizacja i odtworzenie istniejącego majątku [mln zł];

I_t – łączna wartość nakładów inwestycyjnych poniesionych w roku t przez operatora;

$P_{przył(t)}$ – sumaryczna wartość mocy przyłączeniowej na wszystkich poziomach napięcia dystrybucyjnego (inaczej – istniejąca zdolność przyłączeniowa) w roku t [MW];

$P_{przył(t-1)}$ – sumaryczna wartość mocy przyłączeniowej na wszystkich poziomach napięcia dystrybucyjnego w roku $t-1$ [MW];

ΔP_{przyt} – przyrost mocy przyłączeniowej na wszystkich poziomach napięcia dystrybucyjnego [MW]; $\Delta P_{\text{przyt}} = P_{\text{przyt}(t)} - P_{\text{przyt}(t-1)}$;

ΔWRA – przyrost wartości regulacyjnej aktywów w roku t [mln zł]; powinien być odzwierciedleniem działań operatorów potwierdzającym zaangażowanie w inwestycje poprawiające m.in. zdolność przyłączeniową sieci dystrybucyjnych, a także stosowanie innowacyjnych rozwiązań; $\Delta WRA = WRA_{(t)} - WRA_{(t-1)}$.

Jako preferowane zależności wskaźnika E_{ANI} można uznać wzory (8), (11) lub (12).

Nie ulega wątpliwości, że operatorzy sieci dystrybucyjnych powinni dążyć do poprawy efektywności funkcjonowania, między innymi poprzez optymalizację ponoszonych kosztów, a także deterministyczne antycypowanie kosztów zwrotu zaangażowanego majątku – a więc skutecznie zabiegając o właściwe wynagrodzenie za zaangażowany kapitał. Stąd z punktu widzenia regulatora w pełni uzasadniona staje się potrzeba skutecznego oddziaływania na egzekwowanie alokacji środków finansowych w inwestycje priorytetowe. Wydaje się, że właściwym miejscem na uwzględnienie efektywności alokacji środków finansowych przez operatorów w tym szczególnym zakresie jest formuła określająca wynagrodzenie za zaangażowany kapitał. Obecnie jest ona obliczana z zależności ogólnej, w postaci:

$$Z_t = WRA_t \times WACC_t \times Q_t \times WR_t \quad (13)$$

gdzie:

Z_t – zwrot z zaangażowanego kapitału w taryfie na rok t ,

$WACC_t$ – średnioważony koszt kapitału ustalony na rok t ,

Q_t – współczynnik regulacji jakościowej,

WR_t – wskaźnik regulacyjny.

Uzupełnienie zależności (13) o wskaźnik (E_{ANI}) może być dokonane w formie wyodrębnionej lub

eksperycko przez Prezesa URE w ramach wskaźnika regulacyjnego (WR_t), indywidualnie dla każdego operatora.

U podstaw zachodzącego w kraju procesu transformacji energetycznej odnajdujemy precyzyjnie zdefiniowane cele, obejmujące aktywne kształtowanie funkcji bezpieczeństwa oraz działań proekologicznych i prospołecznych. Potwierdzeniem tego są przywołane poniżej wybrane uwarunkowania:

- nadal utrzymujący się systematyczny wzrost znaczenia systemu elektroenergetycznego, czemu sprzyjać będzie rosnące zapotrzebowanie na energię elektryczną w dłuższej perspektywie czasu,
- utrzymujący się progres w zakresie przyłączania odnawialnych źródeł energii do sieci elektroenergetycznej, skutkujący m.in. rosnącym wyzwaniem w zakresie bilansowania systemu elektroenergetycznego,
- dramatyczny poziom potrzeb inwestycyjnych w zakresie sieci elektroenergetycznych (potrzeba nowych inwestycji, znacząca potrzeba modernizacji i CAPEX-owego odtworzenia istniejących aktywów sieciowych),
- problemy z osiągnięciem przy obecnie dostępnych technologiach samowystarczalności energetycznej prosumenckiej/lokalnej,
- spodziewany w nieodległej perspektywie wzrost przyłączeń magazynów energii oraz rozwój usług elastyczności.

Istotne jest, że zdecydowaną większość przedsięwzięć OSD należy traktować jako inwestycje priorytetowe – kluczowe dla transformacji i rozwoju rynku. Takie podejście wymaga wykazania przez OSD szczególnej staranności w priorytetyzacji sieciowych zamierzeń inwestycyjnych, ujmowanych następnie w planach inwestycji/rozwoju, a także stałego monitorowania uzyskanych rezultatów, które powinny być zbieżne z parametrami wpisanymi w kluczowe dokumenty planistyczne (Ministerstwo Klimatu i Środowiska 2021, Urząd Regulacji Energetyki 2022b).

3. Model symulacyjny lokalnych klastrów energetycznych oparty na modelowaniu agentowym i teorii grafów


Współczesne systemy energetyczne stoją przed wyzwaniami wynikającymi z dynamicznego rozwoju sieci. Infrastruktura jest coraz bardziej złożona ze względu na intensywne przyłączanie do niej odnawialnych źródeł energii. Dla optymalizacji wydajności oraz opłacalności inwestycji w tym obszarze kluczowe stają się zaawansowane symulacje i modele systemów energetycznych. Opracowanie koncentruje się na symulacji działania i opłacalności lokalnych klastrów energetycznych.

Głównym celem klastrów jest rozwój energetyki rozproszonej, a więc umożliwienie wykorzystania miejscowych zasobów i potencjału energetycznego. W opracowaniu zaprezentowano schematy ogólne modelowania topologii klastra, który może posłużyć jako podstawa do budowy systemu symulacyjnego dla lokalnych klastrów energetycznych, w szczególności takich, które skupiają użytkowników końcowych (np. gospodarstwa domowe, mikroinstalacje fotowoltaiczne, magazyny energii) czy lokalnych prosumentów. Proponowane podejście wykorzystuje modelowanie agentowe, jak w (Fouladvand 2024, Karaś et Serwatka 2017, Vuthi et al. 2022), co pozwala na realistyczne odwzorowanie zachowań poszczególnych uczestników klastra.

Sieci elektroenergetyczne są z natury systemami złożonymi, charakteryzującymi się skomplikowanymi pętlami sprzężenia zwrotnego i zachowaniami wieloagentowymi, integrującymi różnorodne komponenty, takie jak systemy wytwarzania, dystrybucji, magazynowania i zużycia. Opis struktury klastra jest realizowany przy użyciu teorii grafów (Noack 2007), w której wierzchołki grafów reprezentują poszczególnych uczestników systemu (np. gospodarstwa, budynki komunalne, firmy), natomiast krawędzie przedstawiają fizyczne lub logiczne połączenia między nimi – mogą to być np. linie przesyłowe, umowy o współdzieleniu energii, wspólne magazyny lub punkty przyłączenia do sieci zewnętrznej. Takie podejście umożliwia elastyczne odwzorowanie topologii klastra i wspiera analizę przepływów energii w różnych warunkach.

Kluczowe znaczenie dla funkcjonowania modelu ma prawidłowe określenie parametrów przypisanych do wierzchołków i krawędzi grafu (Rys. 2).

Do wierzchołków przypisywane będą m.in.: profil produkcji i zużycia energii (np. charakterystyka fotowoltaiki, profil zużycia domowego), pojemność i strategia działania magazynów energii, typ użytkownika (konsument, prosument, odbiorca krytyczny), a także preferencje dotyczące współdzielenia energii. Z kolei krawędzie mogą zawierać informacje o maksymalnej przepustowości linii przesyłowej, opóźnieniach i priorytetach przesyłu czy kosztach energii przesyłanej między uczestnikami.



Rys. 2. Prezentacja sposobu modelowania topologii klastra


Model symulacyjny powinien nie tylko koncentrować się na wewnętrznej dynamice klastra, ale także uwzględniać jego interakcje z szerszą siecią lub przynajmniej być zaprojektowany z myślą o skalowalności. Teoria grafów zapewnia niezbędne ramy topologiczne (węzły reprezentujące członków klastra, krawędzie reprezentujące połączenia z powiązanymi wagami dla właściwości fizycznych), podczas gdy modelowanie agentowe nadaje tej strukturze dynamiczne zachowanie, umożliwiając każdemu węzłowi (lub agentowi) działanie autonomiczne i interakcję lokalną. Ta kombinacja pozwala na symulację zarówno statycznej infrastruktury fizycznej, jak i dynamicznych, zdecentralizowanych procesów podejmowania decyzji oraz przepływów energii.

Do modelowania symulacyjnego lokalnych klastrów energetycznych można zaadaptować i wykorzystać koncepcje modeli rynków finansowych dla małych i dużych inwestorów przedstawione w (Karaś et Serwatka 2017, 2021). Głównym tematem artykułu jest analiza warunku braku arbitrażu w dyskretnym modelu rynku finansowego, który nie zakłada identycznych stóp procentowych dla pożyczek i depozytów. Przedmiotem badań jest sprawdzenie, w jaki sposób inwestorzy różnego typu (mali i duzi) mogą mieć odmienne możliwości arbitrażowe w tym samym modelu. Agenci w klastrze energetycznym (np. gospodarstwa domowe, firmy, prosumenci) mogą być modelowani jako podmioty o zróżnicowanych warunkach ekonomicznych. Dla przykładu, mali prosumenci mogą mieć inny dostęp do finansowania inwestycji w OZE lub magazyny energii (analogicznie do różnych stóp procentowych dla pożyczek/depozytów) niż więksi gracze, tacy jak przedsiębiorstwa czy samorządy. Modelowanie tych różnic może prowadzić do bardziej realistycznych symulacji ich decyzji inwestycyjnych i operacyjnych w klastrze. Model symulacyjny może być wykorzystany do testowania mechanizmów cenowych i regulacyjnych w klastrze pod kątem braku arbitrażu. Oznacza to wprowadzenie warunków, w których wszyscy uczestnicy mają równe i sprawiedliwe

szanse na handel energią, a system jest stabilny ekonomicznie. Artykuł (Karaś et Serwatka 2017) przedstawia przykłady (5.3 i 5.4), w których mały i duży inwestor mają różny dostęp do warunków finansowych (np. stóp procentowych), co prowadzi do odmiennych możliwości arbitrażowych. Taką sytuację, na zasadzie analogii, można przenieść na klastery energetyczny. Model symulacyjny dla klastra bada przede wszystkim wpływ zróżnicowanego dostępu do finansowania inwestycji (zakładamy różne koszty kapitału dla inwestycji w OZE czy magazynów energii dla różnych typów uczestników). Ponadto do każdego agenta przypisane są oferty i taryfy (różne między grupami), gdyż czasami więksi odbiorcy lub prosumenci mają dostęp do bardziej korzystnych taryf wewnętrznych w klastrze lub w relacjach z operatorem sieci zewnętrznej. Symulacja takich scenariuszy pozwoli ocenić, jak różnice wpływają na ogólną efektywność klastra, jego odporność oraz sprawiedliwość dystrybucji korzyści wśród uczestników. Aby zwiększyć realizm symulacji, do systemu przypisywane są dane pogodowe. Szczególnym zainteresowaniem objęto wpływ dynamicznych zjawisk atmosferycznych na produkcję energii – np. przesuwające się pasy nasłonecznienia (związane z zachmurzeniem), które będą miały istotny wpływ na generację energii z instalacji fotowoltaicznych. Analogicznie symulowane są również okresy silnego wiatru, które zwiększają produkcję energii z turbin, ale mogą prowadzić do lokalnych nadwyżek i niestabilności systemu. Integracja OZE wymaga uwzględnienia dynamicznych danych pogodowych oraz zaawansowanych modeli predykcyjnych, zdolnych do prognozowania generacji w warunkach zmienności i ekstremalnych zjawisk pogodowych.

Głównym celem opracowania jest stworzenie narzędzia analitycznego, które pozwoli lepiej zrozumieć działanie klastrów energetycznych i umożliwi ich optymalizację (Ding et al. 2023) – szczególnie w kontekście integracji odnawialnych źródeł energii oraz dostosowania ich do warunków zmieniającego się środowiska.

Magazynowanie energii jest kluczowym elementem funkcjonowania klastrów energetycznych i stanowi – obok wytwarzania i dystrybucji – integralny element służący zarządzaniu energią w klastrach, co zostało uwzględnione w badaniach. Model symulacyjny będzie przydatny do optymalizacji wykorzystania magazynów energii (Rys. 3) poprzez testowanie różnych scenariuszy zarządzania przechowywaną energią, strategii ładowania/rozładowania oraz podejmowania decyzji o eksportowaniu energii poza klastery. Ponadto symulacja umożliwi identyfikację słabych punktów w strukturze klastra (takich jak ograniczenia przesyłowe, nierównomierna dystrybucja mocy czy niewystarczająca pojemność magazynowa) i może służyć jako podstawa do projektowania przyszłych inwestycji infrastrukturalnych lub zmian w regulacjach zarządzania energią na poziomie lokalnym.



Rys. 3. Optymalizowanie rozmieszczenia wspólnych magazynów energii

Przedstawiona analiza podkreśla kluczową rolę zaawansowanego modelowania symulacyjnego w projektowaniu, optymalizacji i zarządzaniu klastrami energetycznymi w obliczu rosnącej złożoności współczesnych systemów energetycznych. Modelowanie agentowe (ABM) w połączeniu z teorią grafów stanowi fundamentalne podejście, które umożliwia realistyczne odwzorowanie zdecentralizowanych interakcji, dynamicznych zachowań i zmian strukturalnych typowych dla klastrów energetycznych i inteligentnych sieci.

4. Zastosowanie narzędzi matematyki finansowej w wycenie instrumentów pochodnych oraz inwestycji na rynku energii

Inwestycje rzeczowe, podobnie jak instrumenty finansowe, zwykle wyceniane są na podstawie przewidywanych przepływów pieniężnych. Na rynku energii przepływy bywają zdeterminowane poprzez ceny surowców i produktów tego rynku. Zwłaszcza elektrownie konwencjonalne kupują paliwo i tzw. certyfikaty emisyjne (ponoszą koszty) oraz sprzedają energię elektryczną (mają przychody ze sprzedaży). Powstaje zatem pewien *spread* (różnica wybranych parametrów finansowych).

Na rynku energii elektrycznej wyróżnia się kilka rodzajów spreadu w zależności od rodzaju paliwa użytego przy produkcji energii. W szczególności są to: *dark spread* (węgiel kamienny), *spark spread* (gaz ziemny), *quarkspread* (uran), *clean/green spread* (uwzględniający certyfikaty emisyjne). Przykładowo, *clean spark spread* (CSS) w chwili $t \in [0, T]$ można określić zależnością:

$$CSS(t) = S_e(t) - h_g \cdot S_g(t) - I_g(t) \cdot S_{CO_2}(t) \quad (14)$$

gdzie:

S_e – cena energii elektrycznej,

S_g – cena gazu,

h_g – współczynnik wydajności (*heat rate*) dla bloku gazowego,


I_g – intensywność emisji bloku gazowego,

S_{CO_2} – cena certyfikatów emisyjnych.

Można zatem przyjąć, że wartość CSS w chwili $t \in [0, T]$ to marża brutto energetycznego bloku gazowego, która powinna pokryć wszystkie pozostałe koszty, aby produkcja energii elektrycznej w chwili $t \in [0, T]$ była opłacalna.

Poszczególne parametry takiego spreadu (cena gazu, cena energii elektrycznej itd.) wymagają symulacji zmiany ich wartości w czasie. Stąd, na podstawie danych historycznych (Rys. 4), buduje się modele służące przewidywaniu ich przyszłych wartości.

Jednakże w tym przypadku wymaga to predykcji danych w bardzo odległych horyzontach czasowych, co negatywnie wpływa na wiarygodność rezultatów stosowania tych modeli. Aby ograniczyć błąd prognozy, zamiast analizować dane każdego szeregu czasowego osobno, stosuje się analizę wartości całego spreadu. Jest to podejście dopuszczalne między innymi z uwagi na często występujące wysokie współczynniki korelacji parametrów takiego spreadu (np. ceny gazu i energii elektrycznej). Oczywiście istnieją w tym zakresie pewne ograniczenia: nie zawsze (nie dla każdego zestawu parametrów) *spread* daje się wygodnie modelować – np. ceny gazu i certyfikatów emisyjnych mogą mieć zmienne amplitudy i częstotliwości odchyłków od wartości średniej, a wówczas korzystniejsze byłoby modelowanie każdego parametru osobno.




Rys. 4. Średnia dzienna cena energii elektrycznej na TGE i gazu ziemnego na TTF od 1 stycznia 2015 r. do 14 lipca 2023 r. (opracowanie własne na podstawie Ehrenmann et Smeers 2011, Luna et al. 2013)

Operator bloku generacyjnego ma prawo do przepływów pieniężnych spreadu, czyli *de facto* ma długą pozycję w opcji kupna spreadu. Wciąż aktualna pozostaje dyskusja na temat metod wyceny opcji tego rodzaju. Ze względu na jej specyficzną konstrukcję nie ma wzorów analitycznych jej wyceny, w przeciwieństwie do znanego modelu wyceny opcji europejskich zaproponowanego przez Blacka i Scholesa w 1973 r. (Black et Scholes 1973). Istnieją jednak metody aproksymacji wyceny opcji *spread* (m.in. Carmona et Durrleman 2003 – z pewnym podobieństwem do modelu Blacka-Scholesa). Oczywiście

zawsze można też użyć metody wyceny przez symulacje Monte Carlo.

Specyficzne cechy energii elektrycznej, takie jak brak możliwości przechowywania w skali przemysłowej (stąd duża zmienność cen), sezonowość (w skali dnia, tygodnia, roku) i zdolność powracania cen do średniej (Rys. 5), powodują, że modele cen energii i wycena instrumentów pochodnych na energię nie korespondują z modelami stosowanymi na rynku instrumentów finansowych. Zwykle ceny energii modeluje się procesami powracającymi do wartości średnich z możliwością dodania skoków (np. proces Poissona), co przekłada się na brak zupełności rynku. Najpopularniejszy proces stochastyczny uwzględniający powracanie do wartości średniej to proces Ornsteina-Uhlenbecka.



Rys. 5. Cena energii elektrycznej na TGE w marcu 2024 r. (opracowanie własne na podstawie Kosiorowski et al. 2021)

Formalnie dla ustalonego horyzontu czasowego $T > 0$ proces stochastyczny $X = X(t)$, $t \in [0, T]$ jest procesem Ornsteina-Uhlenbecka o średniej μ , jeśli jest rozwiązaniem stochastycznego równania różniczkowego:

$$dX(t) = \theta \cdot [\mu - X(t)]dt + \sigma \cdot dW(t) \quad (15)$$

gdzie:

σ – zmienność (odchylenie standardowe) tego procesu, $\theta > 0$,

θ – jest parametrem powiązany z „szybkością” powracania do średniej, $\theta > 0$,

$W(t)$ – procesem Wienera, $W = W(t)$ dla $t \geq 0$.

Ze względu na pewne techniczne własności (m.in. istnienie i jedność rozwiązania równania (2)) proces Ornsteina–Uhlenbecka jest bardzo wygodnym narzędziem dla analityków. Na Rys. 6 przedstawiono przykładowe trajektorie procesu o parametrach $\sigma=1$; $\mu=0$; $\theta=0,25$; $X_0=10$, zadanego równaniem:

$$dX(t) = -0,25 \cdot X(t)dt + dW(t) \quad (16)$$




Rys. 6. Prezentacja 1000 przykładowych trajektorii procesu Ornsteina–Uhlenbecka zadanego równaniem (16)

Istnieją też modele, z których wynikają bezpośrednie wzory aproksymujące ceny opcji przy pewnych konkretnych założeniach (Carmona et Durrleman 2003), a które nie wymagają podobnych symulacji. Tego rodzaju modele są kalibrowane na podstawie historycznych danych rynkowych. Na Rys. 7 zaprezentowano brak normalności rozkładu badanej zmiennej, co występuje dość często i może być pewną niewygodą, jednakże do wyznaczenia parametrów równania (15) nie trzeba znać jej rozkładu. Na przykład jako wartość parametru σ można przyjąć historyczne odchylenie standardowe cen energii albo wyliczać tak zwaną wariancję implikowaną.

Główna idea takiego podejścia jest więc zbliżona do standardowych metod wyceny instrumentów pochodnych. Jednakże dodatkowe uwarunkowania rynku energii wymagają użycia bardziej skomplikowanych narzędzi.

Egzotyczne instrumenty pochodne na rynku energii elektrycznej, takie jak opcja *spread*, umożliwiają

modelowanie niepewności przy podejmowaniu decyzji inwestycyjnych oraz elastyczności operacyjnej bloku generacyjnego.



Rys. 7. Histogram i wykres kwantylowy cen energii na Towarowej Giełdzie Energii w Warszawie od 5 czerwca 2023 r. do 14 lipca 2023 r. (opracowanie własne na podstawie Ember b.d.)

5. Zastosowanie metod statystyki matematycznej oraz teorii gier do wyceny inwestycji w energetyce

Badania przedstawione w niniejszym podrozdziale dotyczą głównie zastosowania metod matematycznych,

a w szczególności metod statystyki matematycznej oraz teorii gier, do zagadnień ekonomicznych. W sektorze energetyki mamy do czynienia z wieloma interakcjami między różnego rodzaju podmiotami traktowanymi jako gracze: producentami energii, dostawcami surowców, operatorami systemów przesyłowego i dystrybucyjnych, regulatorem i odbiorcami końcowymi energii. Dlaczego warto stosować teorię gier w energetyce? Po pierwsze, skoro inwestycje w energetyce (np. nowe źródła energii, magazyny energii) często zależą od decyzji innych graczy – konkurencji, regulatorów, odbiorców – to właśnie teoria gier pozwala formalnie modelować cały ten proces. Po drugie, rynek energetyczny charakteryzuje się dużą niepewnością (np. ceny surowców, przyszła polityka klimatyczna, zmiany w miksie energetycznym). Gracze podejmujący decyzje inwestycyjne często muszą uwzględnić zachowanie konkurencji, co idealnie wpisuje się w ramy teorii gier. Trzeci powód wynika z tego, że czasami gracze mogą ze sobą współpracować (np. realizując wspólne projekty, konsorcja), a czasami konkurują ze sobą (np. poprzez walkę o udział w danym rynku).

Teoria gier może w efekcie posłużyć do wyceny projektów OZE. Mianowicie inwestorzy analizują opłacalność farm wiatrowych, fotowoltaicznych czy innych źródeł, uwzględniając decyzje konkurencji (ile farm powstanie, jak wpłynie to na ceny energii). Ponadto można zarządzać ryzykiem poprzez modelowanie gry rynkowej między dostawcami energii a odbiorcami, uwzględniając negocjacje i ryzyka cenowe. Modele teorii gier pomagają także ocenić reakcje rynku na zmiany regulacji. Elektroenergetyczne sieci przesyłowe i dystrybucyjne podlegają regulacjom w zakresie cen, jakości usług i limitów emisji. Interakcja podmiotów konkurujących na rynku energii podlegającym różnym interwencjom regulacyjnym jest zwykle modelowana poprzez modele równowagi, które zapewniają maksymalizację zysku wszystkich uczestników tego rynku. Analiza literatury przedmiotu pokazuje, że model komplementarności maksymalizujący zysk jest matematycznie równoważny grze z agentami minimalizującymi koszty, jeśli zakładamy,

że układ jest deterministyczny albo neutralny względem ryzyka. Dlatego też można i należy zastosować rozwijane metody funkcjonalnej analizy danych, metody analizy wielowymiarowej oraz metody teorii gier do wyceny energetycznych projektów inwestycyjnych (Luna et al. 2013). Można rozważać rynki energii zarówno w układzie deterministycznym, jak i stochastycznym, oraz badać teoretyczne relacje między nimi przy pomocy różnych modeli spotykanych w literaturze przedmiotu (Ehrenmann et Smeers 2011). W tym celu zasadne jest użycie różnych modeli powstałych na gruncie teorii gier. Zastosowanie mogą tu znaleźć zarówno gry kooperacyjne, które korespondują m.in. z szacowaniem alokacji kosztów w spółdzielniach energetycznych, jak i gry niekooperacyjne, które mogą zostać użyte w celu modelowania konkurencji na rynkach energii. Ponadto istotne mogą być gry powtarzające się, których analiza dotyczy inwestycji i decyzji w dłuższym horyzoncie czasowym, oraz gry dynamiczne, które w szczególności uwzględniają ewolucję systemów (w tym np. zmiany technologii czy ceny CO₂).

Do wyceny projektów energetycznych można także zastosować różnego rodzaju metody statystyczne, gdyż pozwalają one radzić sobie z dużą niepewnością, zmiennością warunków oraz ogromną ilością danych. Podobne obciążenia występują w sektorze energetycznym, gdzie codziennością są zmiany cen surowców, wahania popytu, a także korekty regulacyjne czy innowacje technologiczne. Ponadto w energetyce występują stosunkowo duże zbiory danych. Dotyczą one profili produkcji OZE, danych meteorologicznych oraz prognoz cen energii. W tak dynamicznym kontekście ważna jest symulacja ryzyka, która pozwala dokonać oceny wpływu poszczególnych scenariuszy na opłacalność projektu.

Do analizy ryzyka i do przeprowadzania symulacji mogą posłużyć metody statystyczne, np. analiza Monte Carlo. Polega ona na tym, że dokonuje się symulacji setek, tysięcy albo wręcz dziesiątków tysięcy możliwych scenariuszy dotyczących, przykładowo, wahań cen energii albo prognoz produkcji energii w farmach wiatrowych bądź fotowoltaicznych. Następnie

pokazuje się rozkład możliwych wyników finansowych. Ponadto możliwe jest użycie statystycznych modeli ryzyka. Służą one do oceny prawdopodobieństwa niepowodzenia inwestycji wynikającego, np. z ryzyka cenowego albo związanego z zastosowaniem wybranej technologii.

Można dokonywać prognozowania produkcji energii, np. przy użyciu modeli regresji, które sprawdzą się do uzyskania prognozy produkcji energii w farmie wiatrowej albo fotowoltaicznej na podstawie danych meteorologicznych. Z kolei analiza szeregów czasowych służy do prognozowania cen energii na rynkach typu spot.

Statystyczna analiza kosztów i cen powstaje poprzez zastosowanie statystycznych modeli kosztów inwestycji. Możliwa jest analiza kosztów w zależności od lokalizacji czy technologii. Można także modelować popyt i ceny poprzez prognozowanie, jak zmieniają się ceny energii w wyniku realizacji nowych inwestycji. Wreszcie metody statystyczne pomagają dokonać wyceny elastyczności. Skoro bowiem projekty w energetyce mają zwykle wbudowaną elastyczność – rozumianą jako możliwość zmiany zastosowanej technologii oraz, przykładowo, opóźnienie inwestycji – to metody statystyczne i wprost z nimi powiązane metody wyceny opcji rzeczywistych pomagają uzyskać wycenę tak rozumianej elastyczności.

Pewne nowe możliwości niesie zastosowanie metod funkcjonalnej analizy danych do wyceny projektów w energetyce. Funkcjonalna analiza danych (*functional data analysis*, FDA) to nowe, lecz coraz popularniejsze podejście, które znajduje zastosowanie w finansach (Kosiorowski et al. 2021, Kosiorowski et Rydlewski 2020) oraz energetyce. W klasycznej analizie danych analizowane są punkty (np. skalary albo wektory) rozumiane jako dane wielowymiarowe. Tymczasem w podejściu bazującym na FDA analizowane są całe funkcje albo krzywe traktowane jako samodzielne jednostki danych. Przykładowo, zamiast analizować pojedyncze pomiary zużycia energii, można przeprowadzić badania ciągłych krzywych profilu zużycia energii w ciągu doby albo innej jednostki czasu. Metoda funkcjonalnej analizy

danych pozwala między innymi na sprawdzanie profili zużycia energii dla różnych podmiotów. Różni klienci (przykładowo: gospodarstwa domowe i zakłady przemysłowe) charakteryzowani są poprzez różnego rodzaju kształty zużycia energii w ciągu dnia. Metody FDA pozwalają traktować każdy taki profil (np. zużycie energii co 5 minut) jako osobną funkcję. Następnie można badać podobieństwa albo różnice między tymi funkcjami. Pozwala to na dokonanie nowatorskich spostrzeżeń (Rydlewski 2025). Ponadto możliwa jest analiza klastrów profilu zużycia energii, która pozwala na segmentację odbiorców (np. klienci nocni, klienci szczytowi) opartą na całym kształcie profilu zużycia, a nie tylko na sumarycznym zużyciu.

Produkcja energii z farm fotowoltaicznych lub wiatrowych jest zmienna w czasie (profil dzienny lub sezonowy). Tymczasem metody FDA pozwalają na prognozowanie produkcji OZE – i to całej krzywej produkcji, a nie tylko jednej wartości. W efekcie można próbować przewidzieć, jak będzie wyglądał dzienny profil produkcji energii w zależności od pogody, np. wiatru albo nasłonecznienia. Można także dokonać analizy sezonowości i cykliczności. FDA pozwala łatwiej wychwycić sezonowe zmiany w danych – np. profile zużycia latem i zimą. Istnieje również opcja dopasowywania odpowiednich funkcji bazowych i następnie analizowania amplitudy oraz fazy uzyskanych kształtów. W efekcie możliwe jest np. porównanie krzywych produkcji energii dla różnych lokalizacji i badanie, czy występują między nimi istotne różnice (Rydlewski 2025), a także dokonywanie funkcjonalnej analizy składowych głównych (*functional principal component analysis*, FPCA) dla analizowanych krzywych. Można także przeprowadzić funkcjonalną regresję liniową.

Podsumowując, w powyższym fragmencie starano się pokazać, że matematyczna teoria gier oraz rozwijane metody statystyczne, w tym metody funkcjonalnej analizy danych, służą do rozsądnego wyceniania energetycznych projektów inwestycyjnych. Ma to szczególne znaczenie w kontekście bieżącego rozwoju OZE w Polsce.

Bibliografia:

- Black F.S., Scholes M. (1973), *The Pricing of Options and Corporate Liabilities*, „Journal of Political Economy” 81 (3): 637–654.
- Boer F.P. (2000), *Valuation of Technology Using Real Options*, „Research-Technology Management” 43 (4): 26–30.
- Brealey R.A., Myers S.C. (2000), *Principles of Corporate Finance*, 6th Edition, Irwin McGraw-Hill, Boston.
- Buk H. (2018), *Składniki przychodu regulowanego w taryfach dystrybucji energii elektrycznej*, „Prace Naukowe Uniwersytetu Ekonomicznego we Wrocławiu” 513: 35–45.
- Carmona R.A., Durrleman V. (2003), *Pricing and Hedging Spread Options*, „SIAM Review” 45 (4): 627–685.
- Ding Y., Wang O., Tian Z., Lyu Y., Li F., Yan Z., Xia X. (2023), *A Graph-Theory-Based Dynamic Programming Planning Method for Distributed Energy System Planning: Campus Area as a Case Study*, „Applied Energy” 329 (40): 120258.
- Dixit A.K., Pindyck R.S. (1994), *Investment under Uncertainty*, Princeton University Press, Princeton.
- Duffie D. (2001), *Dynamic Asset Pricing Theory*, Princeton University Press, Princeton.
- Ehrenmann A., Smeers Y. (2011), *Generation Capacity Expansion in Risky Environment: A Stochastic Equilibrium Analysis*, „Operations Research” 59 (6): 1332–1346.
- Ember (b.r.), *European Wholesale Electricity Price Data. Wholesale Day-Ahead Electricity Price Data for European Countries, Sourced from ENTSO-e and Cleaned*, <https://ember-climate.org/data-catalogue/european-wholesale-electricity-price-data/> [dostęp: 4.07.2025].
- Eydeland A., Wolyniec K. (2003), *Energy and Power Risk Management – New Developments in Modeling, Pricing, and Hedging*, John Wiley & Sons, Hoboken.
- Fama E.F., French K.R. (1992), *The Cross-Section of Expected Stock Returns*, „Journal of Finance” 47 (2): 427–465.
- Fama E.F., French K.R. (2004), *The Capital Asset Pricing Model: Theory and Evidence*, „Journal of Economic Perspectives” 18 (3): 25–46.
- Fouladvand J. (2024), *Why and How Can Agent-Based Modelling be Applied to Community Energy Systems? A systematic and Critical Review*, „Energy Research & Social Science” 114: 103572.
- Graham J.R., Harvey C.R. (2001), *The Theory and Practice of Corporate Finance: Evidence from the Field*, „Journal of Financial Economics” 60 (2–3): 187–243.
- Hendricks C., Ehrhardt M. (2013), *Clean Spark Options in the German Electricity Market*, preprint BUW-IMACM 13/09.
- Karaś M., Serwatka A. (2017), *Discrete-Time Market Models from the Small Investor Point of View and the First Fundamental-Type Theorem*, „Annales Universitatis Paedagogicae Cracoviensis. Studia Mathematica” 16 (1): 17–40.
- Karaś M., Serwatka A. (2021), *Strong-Hand Conjecture: Agent-Based Numerical Simulation*, „Journal of Investment Strategies” 10 (2): 23–42.
- Kosiorowski D., Rydlewski J. (2020), *Centrality-Oriented Causality: A Study of EU Agricultural Subsidies and Digital Development in Poland*, „Operations Research and Decisions” 30 (3): 47–63.
- Kosiorowski D., Rydlewski J.P., Klecha T., Mielczarek D. (2021), *A New Approach for Analyzing Stock Market Stress Based on the Warsaw Stock Exchange in 2005–2019*, „Eastern European Economics” 59 (4): 317–333.
- Luna J.P., Sagastizabal C., Solodov M. (2013), *Complementarity and Game-Theoretical Models for Equilibria in Energy Markets: Deterministic and Risk-Averse Formulations*, [w:] R.M. Kovacevic, G.Ch. Pflug, M.T. Vespucci (red.), *Handbook of Risk Management in Energy Production and Trading*, Springer Science + Business Media, New York: 231–258.
- Ministerstwo Aktywów Państwowych (2019), *Krajowy plan na rzecz energii i klimatu na lata 2021–2030*, <https://kgm.com/sites/default/files/2024-02/Krajowy%20plan%20na%20rzecz%20energii%20i%20klimatu%20na%20lata%202021-2030.pdf> [dostęp: 4.07.2025].
- Ministerstwo Klimatu i Środowiska (2021), *Załącznik do uchwały nr 22/2021 Rady Ministrów z dnia 2 lutego 2021 r., Polityka Energetyczna Polski do 2040 r.*, https://bip.mos.gov.pl/file-admin/user_upload/bip/strategie_plany_programy/Polityka_energetyczna_Polski/PEP2040_2021-02-02.pdf [dostęp: 4.07.2025].
- Noack A. (2007), *Energy Models for Graph Clustering*, „Journal of Graph Algorithms and Applications” 11 (2): 453–480.
- Rydlewski J.P. (2025), *Wybrane zastosowania metod funkcjonalnej analizy danych w ekonomii*, Wydawnictwa AGH, Kraków.
- Trading Economics (2024), *EU Natural Gas TTF*, <https://tradingeconomics.com/commodity/eu-natural-gas> [dostęp: 4.07.2025].
- Urząd Regulacji Energetyki (2021), *Informacja Prezesa URE w sprawie kalkulacji taryf OSD na 2022*, <https://www.ure.gov.pl/pl/biznes/taryfy-zalozenia/zalozenia-dla-kalkulacji/9961,Informacja-w-sprawie-kalkulacji-taryf-OSD-na-2022-r.html> [dostęp: 4.07.2025].
- Urząd Regulacji Energetyki (2022a), *Informacja Prezesa URE w sprawie kalkulacji taryf OSD na 2023*, <https://www.ure.gov.pl/pl/biznes/taryfy-zalozenia/zalozenia-dla-kalkulacji/10700,Informacja-w-sprawie-kalkulacji-taryf-OSD-na-2023-r.html> [dostęp: 4.07.2025].
- Urząd Regulacji Energetyki (2022b), *Raport zbiorczy z prac Zespołu Projektowego, Karta Efektywnej Transformacji Sieci Dystrybucyjnych Polskiej Energetyki*, <https://www.ure.gov.pl/pl/urzed/informacje-ogolne/aktualnosci/10630,Rynek-energii-elektrycznej-histeryczne-porozumienie-sektorowe-regulatora-i-opera.html> [dostęp: 4.07.2025].
- Urząd Regulacji Energetyki (2024), *Informacja Prezesa URE w sprawie kalkulacji taryf OSD na 2024*, <https://www.ure.gov.pl/pl/biznes/taryfy-zalozenia/zalozenia-dla-kalkulacji/11748,Informacja-w-sprawie-kalkulacji-taryf-OSD-na-2024-r.html> [dostęp: 4.07.2025].
- Ustawa z dnia 10 kwietnia 1997 r. Prawo energetyczne (Dz.U. 1997 nr 54 poz. 348).
- Ustawa z dnia 7 lipca 2023 r. o zmianie Ustawy o przygotowaniu i realizacji strategicznych inwestycji w zakresie sieci przesyłowych oraz niektórych innych ustaw (Dz.U. 2023 poz. 1506).
- Vuthi P., Peters I., Sudeikat J. (2022), *Agent-Based Modeling (ABM) for Urban Neighborhood Energy Systems: Literature Review and Proposal for an all Integrative ABM Approach*, „Energy Inform” 5 (S4): 55.

Economic efficiency of investment projects in the energy sector based on market principles in the conditions of sectoral transformation

Abstract: The overriding development goal of energy companies operating in a competitive energy market is to strive to increase their value through the implementation of investment plans that are developmental, economically efficient and guarantee the safety of the power system. Considering investments in this way determines that in the next decade, mainly projects with a high degree of innovation and streamlining almost all business processes should be implemented. This also means that investment decisions should be based on a thorough and reliable assessment of their profitability and effectiveness, and should also take into account the time

value of money, risk treated as an objectively existing possibility of failure in achieving the intended investment goals and the real life cycle of the investment. For this specific area of issues covered by the investment implementation process, the chapter collects and describes the spectrum of knowledge in the field of determining the energy efficiency of investment projects, defining optimal models for their financing, shaping the regulated revenue of electricity network operators and monitoring the results obtained in relation to the investment outlays incurred, applying innovative methods of agent modelling and graph theory, as well as multidimensional analysis methods and game theory methods for the valuation of energy investment projects.

Keywords: economic efficiency of investment, investment financing, stability of KSE operation, agent modeling, option pricing

prof. dr hab. inż. Waldemar Skomudek
AGH Akademia Górniczo-Hutnicza w Krakowie
Wydział Elektrotechniki, Automatyki,
Informatyki i Inżynierii Biomedycznej
wskomudek@agh.edu.pl



Autorzy poszczególnych części:

1. Wyznaczanie efektywności projektów inwestycyjnych w energetyce

dr Jerzy Dzieża,
Wydział Matematyki Stosowanej AGH

2. Zasady kształtowania przychodu regulowanego operatorów sieci dystrybucyjnej oraz monitorowanie uzyskanych efektów alokacji nakładów inwestycyjnych

prof. dr hab. inż. Waldemar Skomudek,
Wydział Elektrotechniki, Automatyki,
Informatyki i Inżynierii Biomedycznej AGH

3. Model symulacyjny lokalnych klastrów energetycznych oparty na modelowaniu agentowym i teorii grafów

Anna Serwatka,
Wydział Matematyki Stosowanej AGH

4. Zastosowanie narzędzi matematyki finansowej w wycenie instrumentów pochodnych oraz inwestycji na rynku energii

Aleksander Lorenc,
Deloitte Advisory

5. Zastosowanie metod statystyki matematycznej oraz teorii gier do wyceny inwestycji w energetyce

dr Jerzy Rydlewski,
Wydział Matematyki Stosowanej AGH