

## MOŻLIWOŚCI ZWIĘKSZENIA WARTOŚCI RYNKOWEJ PRODUKCJI POPRAZ OPTYMALIZACJĘ HARMONOGRAMÓW PRACY ELEKTROWNI WODNEJ NA DOBĘ NASTĘPNĄ

Tomasz PAKULSKI

Instytut Energetyki Instytut Badawczy Oddział Gdańsk  
tel.: 58 349 8211 e-mail: t.pakulski@ien.gda.pl

**Streszczenie:** Opracowanie ma na celu przedstawienie możliwości zwiększenia wartości rynkowej produkcji elektrowni wodnych (EW) poprzez cenową optymalizację harmonogramów ich pracy na dobę następną. W referacie przedstawiono koncepcję prognozowania cen energii na Towarowej Giełdzie Energii (TGE) na podstawie określonych w Krajowym Systemie Elektroenergetycznym (KSE) warunków popytowo - podaży. Zaprezentowano wyniki testowania oraz walidacji modeli prognostycznych, wykorzystujących metody sztucznej inteligencji, pod kątem poprawności prognozowania oraz odwzorowania dobowych profili cenowych. Wykazano, że poprzez zmianę dobowego harmonogramu pracy EW istnieje możliwość zwiększenia wartości rynkowej produkcji EW w okresie średniorocznym o ok. 5-7 % w stosunku do wariantu aktualnego.

**Słowa kluczowe:** prognozowanie cen energii, sztuczne sieci neuronowe, elektrownia wodna, zwiększenie wartości rynkowej produkcji.

### 1. WSTĘP

Dotychczasowym priorytetem dla pracy EW była maksymalizacja ilości wytwarzanej energii, która wiązała się z maksymalizacją uzyskiwanych przychodów. Historycznie planowanie pracy zbiornikowych EW było w znacznej mierze oderwane od warunków rynkowych i często uwzględniało statycznie określone, rekomendowane harmonogramy produkcji w zależności od wielkości występującego dopływu naturalnego.

Zmiany w systemie wspierania energetyki odnawialnej spowodowały, że EW o mocy zainstalowanej powyżej 5 MW utraciły wsparcie finansowe w postaci świadectw pochodzenia energii oraz zniesiono obowiązek zakupu energii z tych źródeł [1]. W konsekwencji spowodowało to konieczność sprzedaży i rozliczania energii po cenach rynku energii, które w obrębie doby zmieniają się zgodnie z kosztami jej wytwarzania oraz bilansowania KSE. W efekcie, w celu zwiększenia przychodów ze sprzedaży energii, optymalizacji powinien podlegać nie wolumen ich produkcji, ale jej wartość rynkowa. Maksymalizacja produkcji zbiornikowych EW w godzinach o najwyższych cenach energii pozwoli EW na wygenerowanie dodatkowych środków finansowych na częściowe pokrycie utraconych korzyści ze sprzedaży świadectw pochodzenia energii.

W tablicy 1 przedstawiono przykład cenowej optymalizacji harmonogramu pracy EW w wybranej dobie.

Tablica 1. Wpływ zmiany harmonogramu pracy EW na zwiększenie wartości rynkowej produkcji

Godzina doby	Cena energii, PLN/MWh	Przed optymalizacją		Po optymalizacji	
		Produkcja energii, MWh	Przychód ze sprzedaży, PLN	Produkcja, MWh	Przychód ze sprzedaży, PLN
0	135,88	0	0	0	0
1	127,60	0	0	0	0
2	127,45	0	0	0	0
3	127,42	0	0	0	0
4	127,09	0	0	0	0
5	127,70	0	0	0	0
6	153,96	0	0	0	0
7	202,02	0	0	0	0
8	405,90	0	0	0	0
9	881,09	0	0	40	35 244
10	667,46	40	26 872	0	0
11	865,88	41	35 536	40	34 635
12	972,35	41	39 886	40	38 894
13	1135,33	20	23 252	40	45 413
14	764,40	0	0	0	0
15	423,22	0	0	0	0
16	285,94	0	0	0	0
17	200,20	0	0	0	0
18	193,60	20	3 882	0	0
19	197,25	0	0	0	0
20	189,87	0	0	0	0
21	184,55	0	0	0	0
22	151,10	0	0	0	0
23	132,24	0	0	0	0
Razem		163	129 427	160	154 186

### 2. MODELE PROGNOSTYCZNE CEN ENERGII

#### 2.1. Koncepcja realizacji prognoz

Oszacowanie ryzyka pozycji kontraktowej wymaga zastosowania prognoz o wysokim stopniu dokładności dla każdej godziny doby. W tym celu niezbędne jest generowanie trafnych prognoz cen energii, które umożliwią we właściwy sposób zaplanować pracę hydrozespołów w dobie n+1. Hurtowe ceny energii elektrycznej na giełdzie są kształtowane w oparciu o zasady gry rynkowej i charakteryzują się dużą zmiennością w czasie, a w szczególności w obrębie doby.

Zakłada się, że opracowany model prognostyczny będzie wykorzystywany do planowania pracy generacyjnej z dopływu naturalnego. Najistotniejsze znaczenie dla maksymalizacji wartości rynkowej produkcji ma właściwe typowanie godzin, w których spodziewane jest wystąpienie najwyższych cen energii w obrębie doby tak, aby w zależności od możliwości technicznych i ograniczeń hydrologicznych w nich grafikować produkcję w dobie n+1.


Osiągnięcie odpowiedniego poziomu dokładności prognoz cen energii jest trudnym, wysoko złożonym zadaniem. Wymaga nie tylko dysponowania odpowiednimi metodami i narzędziami prognozowania, ale przede wszystkim zgromadzenia dużej bazy danych, historycznych niezbędnych do zbudowania modelu prognostycznego,

w otoczeniu zmieniających się warunków funkcjonowania rynku. Złożoność procesów zachodzących na rynku energii elektrycznej, rzutujących na poziom notowanych cen jest dość znaczna i nie zawsze będzie możliwa do odwzorowania za pomocą opracowanych modeli prognostycznych [2,3,4].

Głównym zadaniem modelu prognostycznego jest predykcja cen energii na TGE w horyzoncie 24 godzin doby następnej (n+1) w rozdzielczości godzinowej. Model prognostyczny opracowano w oparciu o metody sztucznej inteligencji wykorzystujące jednokierunkowe sieci neuronowe zawarte w pakiecie Neural Networks Toolbox środowiska Matlab:

- perceptron jednowarstwowy zbudowany z wykorzystaniem nieliniowych neuronów (N),
- perceptron wielowarstwowy dwuwarstwowy (BP-2L) oraz trójwarstwowy (BP-3L),
- perceptron wielowarstwowy z kaskadowym podawaniem zmiennych wejściowych (dwuwarstwowy (BPC-2L) oraz trójwarstwowy (BPC-3L) w konfiguracji połączeń dodatkowo z pierwszą warstwą ukrytą (BPC-3L1) oraz z obiema warstwami ukrytymi (BPC-3L12),

Ogólną koncepcję działania modelu przedstawiono na rys. 1.



Rys. 1. Idea prognozowania cenę energii na TGE na podstawie historycznych danych opisujących pracę KSE oraz cen TGE

## 2.2. Dane wejściowe

Model prognostyczny wyznacza cenę energii elektrycznej na podstawie określonych dla danej godziny w systemie warunków popytowo-podażowych, będących pochodną:

- przewidywanego poziomu zapotrzebowania na moc w KSE;
- dostępnego potencjału wytwórczego jednostek generacyjnych, uwzględniającego zakres planowanych odstawień i remontów oraz specyfikę ich pracy;
- pracy odnawialnych źródeł energii;
- planowanej wymiany międzysystemowej;
- cen praw do emisji CO<sub>2</sub>;

Do zbudowania i testowania modeli prognostycznych wykorzystano historyczne dane systemowe opisujące pracę KSE [5] oraz dane o hurtowych cenach energii [6] z okresu 01.01.2018 – 31.01.2019r.

Dla właściwego odzwierciedlenia charakterystycznych cech poszczególnych elementów składowych zmiennej prognozowanej dokonano podziału danych wejściowych na część uczącą (U) służącą do trenowania sieci, testującą (T) odpowiedzialną za sprawdzenie jakości nauczonej sieci oraz walidacyjną (W) do oceny trafności prognoz (przypadek A). W celu sprawdzenia zachowania sieci przy różnych danych wejściowych czynności powtórzono dla alternatywnego podziału danych wejściowych na poszczególne części (przypadek B). Przedstawiony podział pozwolił na przetestowanie jakości odwzorowania nauczonej sieci dla różnych okresów czasu, w których mogą występować różne poziomy cen energii na TGE. Dodatkowo umożliwił odpowiedni podział danych, tak aby w każdym zbiorze występowały reprezentatywne próbki danych.

## 2.3. Testowanie i walidacja modeli prognostycznych

Jako miarę błędu prognozowania wykorzystano średni bezwzględny błąd MAE (ang. *Mean Absolute Error*), opisany zależnością:

$$MAE = \frac{1}{n} \sum_{i=1}^n |x_{R(i)} - x_{P(i)}| \quad (1)$$

gdzie:  $n$  – liczba pomiarów,  $x_{R(i)}$  – kolejna wartość empiryczna,  $x_{P(i)}$  – kolejna wartość prognozowana.

W celu graficznego porównania wielkości prognozowanych z empirycznymi wykorzystano współczynnik determinacji  $R^2$  opisany zależnością:

$$R^2 = \frac{\sum_{i=1}^n (x_{P(i)} - x_{R(sr)})^2}{\sum_{i=1}^n (x_{R(i)} - x_{R(sr)})^2} \quad (2)$$

gdzie:  $n$  – liczba pomiarów,  $x_{R(i)}$  – kolejna wartość empiryczna,  $x_{P(i)}$  – kolejna wartość prognozowana,  $x_{R(sr)}$  – średnia wartość empiryczna

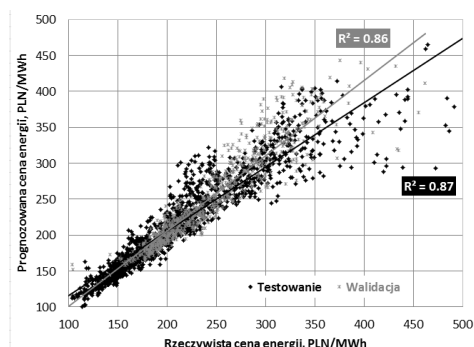
Wyniki testowania i walidacji modeli przedstawiono w tablicach 2 i 3 oraz na rys. 2-4.

Tablica 2. Porównanie błędu MAE prognozowania cen energii przy użyciu różnych sieci neuronowych


Model sieci	Błąd MAE, [PLN/MWh]					
	Przypadek A			Przypadek B		
	T	W	T+W	T	W	T+W
N	18,3	21,0	<b>19,2</b>	18,0	20,0	<b>18,7</b>
BP-2L	16,8	16,6	<b>16,7</b>	17,5	17,2	<b>17,4</b>
BPC-2L	16,9	17,8	<b>17,2</b>	17,4	18,0	<b>17,6</b>
BP-3L	16,8	16,7	<b>16,8</b>	17,3	16,9	<b>17,2</b>
BPC-3L1	16,7	17,2	<b>16,8</b>	17,2	16,6	<b>17,0</b>
BPC-3L12	16,6	17,0	<b>16,7</b>	17,1	16,5	<b>16,9</b>

Tablica 3. Porównanie współczynników determinacji  $R^2$  prognozowania cen energii dla różnych sieci neuronowych

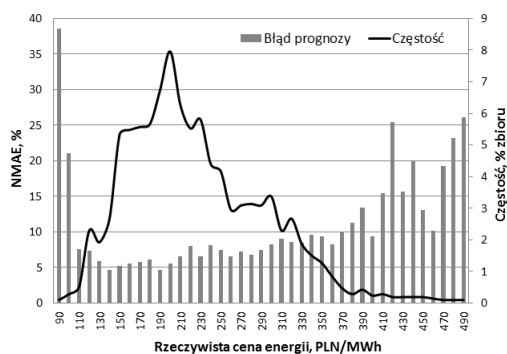
Model sieci	Współczynnik determinacji $R^2$ , [-]					
	Przypadek A			Przypadek B		
	T	W	T+W	T	W	T+W
N	0,86	0,85	<b>0,86</b>	0,79	0,82	<b>0,79</b>
BP-2L	0,87	0,87	<b>0,87</b>	0,80	0,84	<b>0,81</b>
BPC-2L	0,87	0,87	<b>0,87</b>	0,80	0,83	<b>0,80</b>
BP-3L	0,87	0,86	<b>0,87</b>	0,80	0,84	<b>0,81</b>
BPC-3L1	0,87	0,86	<b>0,87</b>	0,80	0,84	<b>0,81</b>
BPC-3L12	0,87	0,86	<b>0,87</b>	0,80	0,85	<b>0,81</b>



Rys. 2. Porównanie prognoz cen energii z danymi empirycznymi w okresie testowania i walidacji



Rys. 3. Porównanie prognozy cen energii z danymi empirycznymi w wybranym ciągłym 14-dniowym okresie czasu



Rys. 4. Znormalizowany względem średniej ceny energii na TGE w poszczególnych przedziałach błąd prognozy MAE na tle rozkładu częstości występowania cen energii w okresie testowania i walidacji

W celu sprawdzenia poprawności odwzorowania prognozowanych dobowych profili, ceny energii w poszczególnych dobach uszeregowano od najwyższych (liczba 1) do najniższych (liczba 24), tworząc tzw. rankingi cenowe.

W tabelicy 4 przedstawiono statystykę rankingów cenowych wykonanych według cen prognozowanych oraz rzeczywiście występujących na TGE w poszczególnych dobach n+1. Wartości liczbowe w macierzy oznaczają prawdopodobieństwo zgodności typowania godzin występowania kolejnych cen w dobie n+1 (od najwyższej do najniższej). W sytuacji idealnej, w której występowałaby pełna zgodność prognozowanych profili cenowych z rzeczywistymi, wartości na przekątnej macierzy miałyby wartość równą 100 a pozostałe byłyby równe 0.

Tabela 4. Statystyka rankingów cenowych wykonanych według cen prognozowanych oraz rzeczywiście występujących na TGE w poszczególnych dobach n+1 w okresie testowania i walidacji

Ranking prognozowanej ceny energii w dobie: (1) cena najwyższa, (24) cena najniższa																										
		1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	
Ranking rzeczywistej ceny energii w dobie: (1) cena najwyższa, (24) cena najniższa	1	89,4	21,3	15,7	3,4	6,7	2,2	0,0	0,0	0,0	0,0	1,1	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	
	2	23,6	37,1	14,6	9,0	3,4	4,5	2,2	2,2	2,2	1,1	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	
	3	15,7	40,4	11,2	5,6	3,4	3,4	4,5	0,0	2,2	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	
	4	5,6	9,0	6,7	31,5	16,9	9,0	7,9	1,1	6,7	4,5	0,0	1,1	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	
	5	3,4	4,5	3,4	19,1	21,3	13,5	11,2	2,2	6,7	4,5	5,6	1,1	1,1	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	1,1	0,0	0,0	
	6	1,1	2,2	5,6	6,7	18,0	20,2	16,9	15,7	4,5	0,0	2,2	2,2	0,0	1,1	0,0	0,0	2,2	0,0	0,0	0,0	0,0	0,0	0,0	0,0	1,1
	7	1,1	3,4	4,5	5,6	10,1	11,2	21,3	14,6	9,0	7,9	2,2	1,1	2,2	4,5	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	1,1
	8	1,1	0,0	0,0	4,5	6,7	15,7	12,4	19,1	12,4	11,2	5,6	1,1	3,4	2,2	1,1	0,0	1,1	0,0	1,1	0,0	1,1	0,0	0,0	0,0	0,0
	9	1,1	2,2	4,5	3,4	3,4	2,2	10,1	11,2	9,0	19,1	11,2	10,1	5,6	2,2	2,2	2,2	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0
	10	0,0	2,2	1,1	2,2	2,2	6,7	5,6	6,7	14,6	12,4	15,7	7,9	3,4	7,9	2,2	5,6	0,0	1,1	0,0	1,1	0,0	1,1	0,0	0,0	0,0
	11	0,0	0,0	0,0	2,2	3,4	4,5	3,4	7,9	10,1	16,9	12,4	11,2	12,4	6,7	4,5	2,2	1,1	0,0	0,0	1,1	0,0	1,1	0,0	0,0	0,0
	12	0,0	0,0	2,2	0,0	1,1	5,6	3,4	4,5	11,2	6,7	10,1	21,3	18,0	7,9	3,4	1,1	1,1	1,1	1,1	0,0	0,0	0,0	0,0	0,0	0,0
	13	0,0	1,1	0,0	0,0	0,0	1,1	4,5	7,9	4,5	14,6	12,4	21,3	18,0	3,4	6,7	1,1	1,1	0,0	0,0	1,1	0,0	0,0	1,1	0,0	0,0
	14	0,0	1,1	1,1	0,0	0,0	1,1	4,5	3,4	2,2	7,9	10,1	15,7	30,3	14,6	3,4	2,2	1,1	0,0	1,1	0,0	1,1	0,0	0,0	0,0	0,0
	15	0,0	0,0	0,0	0,0	1,1	0,0	0,0	1,1	1,1	3,4	3,4	9,0	11,2	11,2	28,1	20,2	2,2	3,4	1,1	0,0	1,1	0,0	1,1	0,0	0,0
	16	0,0	0,0	0,0	1,1	0,0	0,0	0,0	1,1	1,1	3,4	3,4	2,2	3,4	23,6	42,7	10,1	3,4	0,0	1,1	1,1	0,0	1,1	0,0	0,0	2,2
	17	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	1,1	3,4	2,2	2,2	4,5	9,0	31,7	15,7	4,5	2,2	1,1	1,1	0,0	1,1	0,0	0,0	0,0
	18	0,0	0,0	0,0	0,0	0,0	1,1	0,0	0,0	1,1	1,1	1,1	1,1	0,0	4,5	14,6	39,3	18,0	3,4	7,9	1,1	0,0	1,1	0,0	0,0	1,1
	19	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	1,1	0,0	0,0	3,4	0,0	4,5	22,5	43,8	14,6	4,5	1,1	3,4	1,1	0,0	0,0
	20	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	1,1	1,1	1,1	1,1	3,4	10,1	37,1	16,9	13,5	5,6	9,0	0,0	0,0	0,0	0,0
	21	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	1,1	0,0	1,1	0,0	0,0	0,0	3,4	15,7	33,7	18,0	19,1	4,5	0,0	0,0	0,0
	22	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	1,1	0,0	0,0	1,1	0,0	0,0	2,2	1,1	9,0	14,6	19,1	20,2	22,5	0,0	0,0
	23	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	1,1	0,0	0,0	2,2	0,0	1,1	3,4	4,5	3,4	6,7	21,3	25,8	30,3	0,0	0,0
	24	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	1,1	0,0	0,0	1,1	3,4	0,0	3,4	10,1	7,9	22,5	23,6	27,0	0,0	0,0	0,0

Sprawdzalność prognozy, % zdarzeń

### 3. MOŻLIWOŚCI ZWIĘKSZENIA WARTOŚCI RYNKOWEJ PRODUKCJI

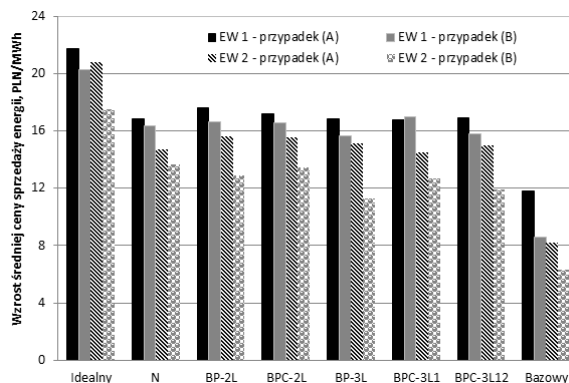
Opracowany model prognostyczny cen energii wykorzystano do oszacowania możliwego wzrostu wartości rynkowej produkcji energii w wybranych EW na skutek zmiany harmonogramu pracy w dobie n+1 w wariancie:

- idealnym, tj. pełnej wiedzy na temat cen energii na dobę n+1 w momencie ustalania harmonogramu;
- realnym tj. harmonogram pracy EW wynika z cen prognozowanych na dobę n+1.

W analizie wykorzystano dane o rzeczywistej produkcji z wybranych elektrowni (EW-1 oraz EW-2) z dni, w których testowano i walidowano moduł prognostyczny cen energii [5]. W rozważaniach założono pracę z mocą optymalną wynikającą z charakterystyki sprawności hydrozespołów. Każdorazowo zachowywano dobową wielkość produkowanej energii, a pracę hydrozespołów przesuwano na okresy, w których prognozowano występowanie najwyższych cen w poszczególnych dobach. Dodatkowo sprawdzono, czy przesunięcie produkcji na inne godziny doby nie będzie wpływało na przekroczenie dopuszczalnych poziomów zbiorników, wynikających z wielkości występującego dopływu naturalnego [7,8].

Wyniki porównywano z modelem bazowym, w którym założono grafowanie produkcji w poszczególnych godzinach doby według stałego harmonogramu w podziale na sezon zimowy (październik - marzec) oraz letni (kwiecień - wrzesień).

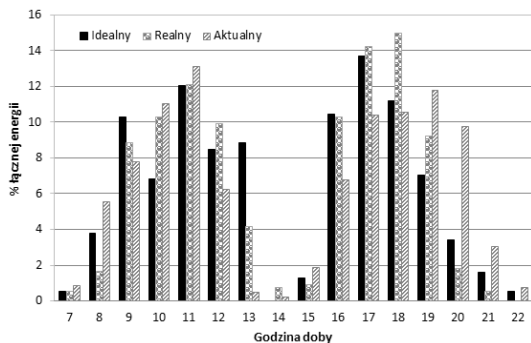
Wyniki analiz przedstawiono w tabelicy 5 oraz na rys. 5-6. Wartości dotyczące zwiększenia wartości rynkowej produkcji odnoszą się do aktualnej pracy wybranych EW.



Rys. 5. Możliwości zwiększenia wartości rynkowej produkcji EW poprzez zmianę harmonogramu pracy

Tabela 5. Możliwości zwiększenia wartości rynkowej produkcji w wybranych elektrowniach wodnych (EW-1) oraz (EW-2).

Model	Zwiększenie wartości produkcji, %			
	EW-1		EW-2	
	Przyp.A	Przyp.B	Przyp.A	Przyp.B
Idealny	9,5	8,6	8,7	7,1
N	7,3	6,9	6,2	5,5
BP-2L	7,7	7,0	6,5	5,2
BPC-2L	7,5	7,0	6,5	5,4
BP-3L	7,3	6,6	6,3	4,5
BPC-3L1	7,3	7,2	6,1	5,1
BPC-3L12	7,4	6,7	6,3	4,8
Bazowy	5,2	3,6	3,4	2,6



Rys. 6. Rozkład dobowy energii w poszczególnych godzinach doby

#### 4. PODSUMOWANIE I WNIOSKI

Badania modeli prognostycznych wykazały, że:

- istnieje możliwość prognozowania cen energii w dobie  $n+1$  z błędem MAE ok. 17 PLN/MWh (przy średniej cenie energii na poziomie ok. 223 PLN/MWh błąd względny będzie wynosił ok. 8 %, a  $R^2 > 0,8$  wskazuje na dopasowanie „dobre” modelu);
- wybór modelu neuronowego nie ma istotnego znaczenia dla zwiększenia dokładności prognozy;
- zbliżone błędy uzyskane w okresie testowania i walidacji (dla różnych zestawów danych wejściowych) wskazują na poprawność działania modelu;
- wielkość błędu prognozy jest ściśle zależna od ilości próbek w danym zbiorze (zbyt mała liczba danych powoduje, że model nie jest w stanie prawidłowo odwzorowywać zmienności prognozowanej cechy);
- model prognostyczny właściwie odzwierciedla dobowe profile cenowe (z prawdopodobieństwem ok. 75 % przy pracy EW przez 3 godziny w dobie), ze względu na występowanie niewielkich różnic pomiędzy wartościami cen energii, możliwe jest wskazanie godzin sąsiednich o nieco niższych cenach.

Wykazano, że poprzez zmianę dobowego harmonogramowania pracy EW istnieje możliwość zwiększenia wartości rynkowej produkcji EW w okresie średniorocznym o ok. 5-7 % w stosunku do wariantu aktualnego (przy założonej rzeczywiście występującej produkcji w analizowanym okresie czasu). W rozważaniach założono pełną dostępność zasobów wytwórczych. W niektórych przypadkach niedyspozycyjność hydrozespołów wynikająca z remontów lub awarii może powodować, że praca według optymalnego grafiku będzie

niemożliwa, co będzie wiązało się ze zmniejszeniem oczekiwanego przychodu. Poziom wzrostu wartości rynkowej będzie zależny od wielkości dopływu naturalnego. Największe możliwości będą istniały w okresach wysokiego dopływu, gdy alokacja pracy EW będzie obejmować większą liczbę godzin w dobie. Dalsza możliwość zwiększenia wartości rynkowej produkcji będzie istniała w przypadku wykorzystania potencjalnych zdolności pompowych EW (jeśli takowe by istniały) i planowaniu dodatkowych cykli generacji - pompowanie w godzinach, w których oczekiwane byłoby duże rozchylenie cen energii oraz spodziewany byłby niewielki dopływ naturalny.

#### 5. BIBLIOGRAFIA

1. Ustawa z dnia 20 lutego 2015r. o odnawialnych źródłach energii. Opracowano na podstawie: t.j. Dz. U. z 2018 r. poz. 1269, 1276, 1544, 1629, 1669, 2245, Kancelaria Sejmu, (Art. 42 pkt 7 str.42, Art. 42 pkt 11 str. 48);
2. Miller A, Bućko P.: Zastosowanie sztucznych sieci neuronowych do prognozowania cen na giełdzie energii, Zeszyty Naukowe Wydziału Elektrotechniki i Automatyki Politechniki Gdańskiej Nr 40, XXIV Seminarium Zastosowanie komputerów w nauce i technice 2014, Oddział Gdański PTETiS;
3. Nargale K.K., Patil S.B.: Day ahead price forecasting in deregulated electricity market using Artificial Neural Network, International Conference on Energy Efficient Technologies for Sustainability (ICEETS), April 2016
4. Beigaitė R., Krilavičius T., Lok Man K.: Electricity Price Forecasting for Nord Pool Data, 2018 International Conference on Platform Technology and Service (PlatCon), January 2018;
5. Polskie Sieci Elektroenergetyczne <https://www.pse.pl/> (data dostępu 4.02.2019r.)
6. Towarowa Giełda Energii SA <https://tge.pl/> (data dostępu 5.02.2019r.)
7. Instytut Meteorologii i Gospodarki Wodnej <https://danepubliczne.imgw.pl/> (data dostępu 5.02.2019r.)
8. Guerreiro C.A., Saraiva J.T., Sousa J.C., Mendes V.T.: Operation planning of hydro stations using generative algorithms considering their impact on the electricity market prices, 11th International Conference on the European Energy Market (EEM14), May 2014

### POSSIBILITIES TO INCREASE PRODUCTION MARKET VALUE THROUGH A DAY AHEAD HYDRO POWER PLANT SCHEDULES OPTIMIZATION

The study aims at presenting the possibilities of hydropower plants (HPPs) market value production increase through a day ahead pricing schedule optimization. The change of HPPs planning system in Poland results from the new provisions introduced in national legislation, in particular from the validity of the renewable energy sources act. The approach presented in this paper is based on the change of current HPPs schedules by using energy price forecasts. The paper presents the concept of energy price forecasting at the Polish Power Exchange (PPE) based on the demand and supply conditions defined in the National Power System. The results of testing and validation forecast models using artificial intelligence methods were presented. The research was carried out to check correctness of forecasting systems and the mapping of daily price profiles in various conditions. It has been shown that it is possible to increase the HPPs production market value by changing the daily HPPs operation schedule by about 5-7% compared to the present case. The risk factors that may contribute to the reduction of the expected income were indicated. Potential areas for further growth in the production market value were presented.

**Keywords:** energy prices forecasting, artificial neural network, hydropower plant, market value production increase.