

UNIVERZA V LJUBLJANI  
EKONOMSKA FAKULTETA

MAGISTRSKO DELO

**NAPOVEDOVANJE GIBANJA CEN ELEKTRIČNE ENERGIJE V  
SLOVENIJI S POMOČJO STROJNEGA UČENJA**

Ljubljana, maj 2023

MANCA FRONTINI

## IZJAVA O AVTORSTVU

Podpisana Manca Frontini, študentka Ekonomske fakultete Univerze v Ljubljani, avtorica predloženega dela z naslovom Napovedovanje gibanja cen električne energije v Sloveniji s pomočjo strojnega učenja, pripravljenega v sodelovanju s svetovalcem doc. dr. Luko Tomatom

### IZJAVLJAM

1. da sem predloženo delo pripravila samostojno;
2. da je tiskana oblika predloženega dela istovetna njegovi elektronski obliki;
3. da je besedilo predloženega dela jezikovno korektno in tehnično pripravljeno v skladu z Navodili za izdelavo zaključnih nalog Ekonomske fakultete Univerze v Ljubljani, kar pomeni, da sem poskrbela, da so dela in mnenja drugih avtorjev oziroma avtoric, ki jih uporabljam oziroma navajam v besedilu, citirana oziroma povzeta v skladu z Navodili za izdelavo zaključnih nalog Ekonomske fakultete Univerze v Ljubljani;
4. da se zavedam, da je plagiatorstvo – predstavljanje tujih del (v pisni ali grafični obliki) kot mojih lastnih – kaznivo po Kazenskem zakoniku Republike Slovenije;
5. da se zavedam posledic, ki bi jih na osnovi predloženega dela dokazano plagiatorstvo lahko predstavljalo za moj status na Ekonomski fakulteti Univerze v Ljubljani v skladu z relevantnim pravilnikom;
6. da sem pridobila vsa potrebna dovoljenja za uporabo podatkov in avtorskih del v predloženem delu in jih v njem jasno označila;
7. da sem pri pripravi predloženega dela ravnala v skladu z etičnimi načeli in, kjer je to potrebno, za raziskavo pridobila soglasje etične komisije;
8. da soglašam, da se elektronska oblika predloženega dela uporabi za preverjanje podobnosti vsebine z drugimi deli s programsko opremo za preverjanje podobnosti vsebine, ki je povezana s študijskim informacijskim sistemom članice;
9. da na Univerzo v Ljubljani neodplačno, neizključno, prostorsko in časovno neomejeno prenašam pravico shranitve predloženega dela v elektronski obliki, pravico reproduciranja ter pravico dajanja predloženega dela na voljo javnosti na svetovnem spletu preko Repozitorija Univerze v Ljubljani;
10. da hkrati z objavo predloženega dela dovoljujem objavo svojih osebnih podatkov, ki so navedeni v njem in v tej izjavi.

V Ljubljani, dne \_\_\_\_\_

Podpis študentke: \_\_\_\_\_

# KAZALO

<b>1</b>	<b>UVOD</b> .....	<b>1</b>
<b>2</b>	<b>TRG ENERGENTOV V EVROPSKI UNIJI</b> .....	<b>4</b>
2.1	Nafta .....	5
2.2	Premog .....	6
2.3	Zemeljski plin .....	7
2.4	Jedrska energija .....	8
2.5	Obnovljivi viri energije.....	9
2.6	Trgovanje z energenti .....	10
2.7	Podatkovna analitika na področju trgovanja z energenti .....	12
<b>3</b>	<b>TRG ELEKTRIČNE ENERGIJE</b> .....	<b>13</b>
3.1	Trgovanje z električno energijo .....	13
3.1.1	Promptni trg .....	13
3.1.2	Izravnalni trg.....	15
3.1.3	Terminski trg .....	15
3.1.4	Bilateralni trg .....	16
3.2	Oblikovanje cen električne energije .....	17
3.3	Zasnova trga električne energije.....	19
3.3.1	Udeleženci na trgu z električno energijo .....	19
3.3.2	Oblike elektroenergetskih trgov .....	19
3.4	Slovenski trg električne energije.....	22
<b>4</b>	<b>METODE IN TEHNIKE PODATKOVNE ANALITIKE ZA NAPOVEDOVANJE PRIHODNJIH DOGODKOV</b> .....	<b>23</b>
4.1	Statistične metode.....	24
4.2	Metode strojnega učenja.....	25
4.3	Modeli za napovedovanje gibanja cen električne energije.....	25
<b>5</b>	<b>NAPOVED GIBANJA CEN ELEKTRIČNE ENERGIJE V SLOVENIJI</b> .....	<b>29</b>
5.1	Opis metodologije.....	30
5.2	Podatki o preteklem gibanju cen električne energije v Sloveniji.....	35
5.3	Izgradnja modela za napovedovanje gibanja cen električne energije.....	37
5.4	Aplikacija modela na podatke.....	40
5.5	Napoved gibanja cen električne energije v Sloveniji .....	41

<b>6</b>	<b>DISKUSIJA</b> .....	<b>43</b>
6.1	Ključne ugotovitve .....	43
6.2	Pomen ugotovitev za podjetja .....	44
6.3	Omejitve raziskave .....	45
6.4	Priložnosti za nadaljnje delo .....	46
<b>7</b>	<b>SKLEP</b> .....	<b>47</b>
	<b>LITERATURA IN VIRI</b> .....	<b>48</b>

## KAZALO TABEL

Tabela 1: Metapodatki o vhodnih spremenljivkah .....	32
Tabela 2: Opisna statistika .....	35
Tabela 3: Rezultati .....	40

## KAZALO SLIK

Slika 1: Grafični prikaz gibanja cen električne energije na borzi South Pool v letih 2017 in 2018.....	36
Slika 2: Povprečna mesečna cena (EUR/MWh) električne energije na slovenski borzi South pool med leti 2017 in 2018 .....	36
Slika 3: Predprocesiranje podatkov v programu RapidMiner .....	37
Slika 4: Proces izgradnje modela v programu RapidMiner .....	38
Slika 5: Podproces znotraj navzkrižne validacije.....	38
Slika 6: Napoved gibanja cene za dan vnaprej z metodo XGBoost .....	39
Slika 7: Napoved gibanja cene za dan vnaprej z metodo SVM .....	39
Slika 8: Proces v programu RapidMiner .....	41
Slika 9: Napoved povprečne dnevne cene z metodo Holt-Winters.....	42
Slika 10: Napoved povprečne dnevne cene z metodo ARIMA .....	42

## SEZNAM KRATIC

angl. – angleško

**ARIMA** – (angl. autoregressive integrated moving average process); avtoregresijski integrirani proces drsečih sredin

**ARMA** – (angl. autoregressive moving average process); avtoregresijski proces drsečih sredin

**ARSO** – Agencija Republike Slovenije za okolje

**DNN** – (angl. deep neural network); globoke nevronske mreže

**ENTSO-E** – Evropsko združenje sistemskih operaterjev elektroenergetskega omrežja

**EU** – (angl. European Union); Evropska unija

**GARCH** – (angl. Generalized Autoregressive Conditional Heteroskedasticity); splošna avtoregresivna pogojna heteroskedastičnost

**GRU** – (angl. gated reccurent unit); zaporne ponavljajoče se enote

**LSTM** – (angl. long short-term memory); dolgotrajni kratkoročni spomin

**MAPE** – (angl. mean absolute percentage error); relativna napaka

**MAE** – (angl. mean absolute error); absolutna napaka

**NYMEX** – (angl. New York Mercantile Exchange); Newyorška blagovna borza

**OECD** – (angl. Organisation for Economic Co-operation and Development); Organizacija za gospodarsko sodelovanje in razvoj

**OPEC** – (angl. Organization of the Petroleum Exporting Countries); Organizacija držav izvoznic nafte

**OTC** – (angl. over the counter); bilateralno trgovanje

**RMSE** – (angl. root mean squared error); koren srednje kvadratne napake

**RNN** – (angl. reccurent neural network); ponavljajoče se nevronske mreže

**SVM** – (angl. support vector machine); metoda podpornih vektorjev

**XGBoost** – (angl. extreme gradient boosted trees); algoritem ekstremnega gradientnega spodbujanja

**ZDA** – Združene države Amerike



# 1 UVOD

Evropski trg energentov velja za visoko razdrobljenega, pri čemer integracijo trga omejuje tehnična kompleksnost panoge, geografske značilnosti Evrope in odsotnost političnega zavzemanja na nacionalnem nivoju držav članic (Delgado, 2008). Zaradi prej omenjenih razlogov je Evropska unija (v nadaljevanju EU) v letu 1996 uvedla liberalizacijo trga električne energije in plina. S tem je bil zasnovan enotni trg, ki je potrošnikom omogočal nakup energentov od katerega koli ponudnika. Hkrati takšen ukrep povzroči razvoj konkurence in investicije v nove tehnologije, na drugi strani pa boljša stroškovna učinkovitost privede do znižanja cen. Pred liberalizacijo trga je v večini držav znotraj EU običajno eno, vertikalno integrirano podjetje poskrbelo za oskrbo z električno energijo. Cilj ustanovitve enotnega evropskega trga energentov je bil ustvariti dobro delujoč evropski trg energentov, vzporedno pa tudi zagotoviti pravičnost in zaščito potrošnikov ter zadostne povezovalne kapacitete in proizvodnje energije (Iovino in Tsitsianis, 2020).

Slovenija se je k liberalizaciji trga električne energije zavezala v letu 2001 in se v celoti odprla v letu 2007. V začetku so bili učinkov liberalizacije deležni večji odjemalci, nato so sledili še manjši, ki so s tem pridobili možnost samostojne izbire dobavitelja elektrike. Podjetja, ki se ukvarjajo s pridobivanjem električne energije, so s tem lahko začela na slovenskem in evropskem trgu delovati samostojno glede na sistemske operaterje.

Slovenski trg električne energije se deli na veleprodajni in maloprodajni trg. Na veleprodajnem so prisotni proizvajalci, trgovci in distributerji električne energije, ki medsebojno poslujejo na podlagi zaprtih pogodb, v katerih pogodbeni stranki vnaprej določita količine in časovni potek dobave električne energije, cena pa ni odvisna od realizacije pogodb. Na borzah električne energije se trguje za dan vnaprej, znotraj dneva in za namen izravnave sistema ali s terminskimi produkti. Na maloprodajnem trgu sodelujejo dobavitelji in odjemalci, ki med seboj sklepajo odprte pogodbe. Za njih časovni okvir dobave in količine niso vnaprej določene, cena elektrike pa se določi na podlagi dejanske porabe (Agencija Republike Slovenije za energijo, 2014). Na slovenskem veleprodajnem trgu prodajajo električno energijo tudi tuji trgovci (Agencija Republike Slovenije za energijo, 2008). Izmenjava električne energije z Avstrijo, Italijo in Hrvaško zagotavlja ravnovesje elektroenergetskega sistema (Agencija Republike Slovenije za energijo, 2021). Slovenski trg meji na štiri velike evropske trge električne energije – italijanski, avstrijski, nemški in trg jugovzhodne Evrope. V okviru medregijskega spajanja je bila Slovenija v letu 2020 na trgu za dan vnaprej povezana v enoten trg z Avstrijo, Italijo in Hrvaško. Slovenski trg je bil z Avstrijo in Hrvaško vključen v enoten evropski trg na področju trgovanja znotraj dneva, z Italijo pa ostajajo v veljavi dopolnilne regionalne dražbe znotraj dneva (Agencija Republike Slovenije za energijo, 2021). Dobavitelji imajo različne pristope k poslovanju, saj se nekateri odločijo za dobavljanje energije zgolj gospodinjstvom, drugi pa poslovnim odjemalcem. V večji meri se sicer odločijo za dobavljanje energije obojim. Dobavitelji ponujajo svojim odjemalcem različne produkte, ki so hkrati s pogoji dobave oblikovani individualno.

Odjemalci se pri izbiri osredotočajo tudi na dodatne storitve, ki jih ponuja dobavitelj, možnosti nakupa sodobnih rešitev za oskrbo z energijo, plačilo storitev, zaupanje v blagovno znamko ipd. (Agencija Republike Slovenije za energijo, 2021).

Trg energentov se je moral v zadnjih letih prilagoditi številnim spremembam na ekonomskem in tehničnem področju. Trg mora poslati prave informacije o cenah, saj na ta način spodbudi učinkovito proizvodnjo in investiranje v izbrane resurse. Zaradi visokih cen transformacijskega omrežja je trg električne energije veljal za naravno monopolni trg. Električna energija se precej razlikuje od ostalih surovin, obenem pa tudi sam trg velja za kompleksnega. Električne energije ni možno hraniti, poleg tega pa je treba zagotavljati stalno ravnovesje med ponudbo in povpraševanjem z namenom zagotavljanja stabilnosti celotnega sistema (Cramton, 2017). Amjady in Hemmati (2006) izpostavita dva instrumenta za trgovanje. V prvem primeru gre za borzo, kjer proizvajalci podajo ponudbe, ki vključujejo količine in cene, enako pa storijo tudi stranke. Pri tem so cene objavljene za dan vnaprej. Stranke se želijo zavarovati pred dnevnim nihanjem cen in trgujejo na podlagi bilateralnih pogodb, s katerimi se dobavitelj in kupec zavežeta o količini in določeni ceni. Posebnost trga električne energije je tudi določanje cen. V primeru enotnih cen se izhodiščna cena določi na podlagi mejnih ponudb. Struktura cene lahko temelji tudi na plačilih po ponudbi. Pri določanju cen lahko pride tudi do izjeme v primeru višje porabe, saj se v tem primeru cena določi glede na mejno porabo določenega območja. Cena med območji se razlikuje, znotraj območja pa je enaka (Singhal in Swarup, 2011).

Liberalizacija je pomenila velike spremembe za trgovanje z električno energijo. Poleg tega ima električna energija kot surovina nekatere posebnosti, ki jih na drugih trgih ne zasledimo. Potrebno je stalno ravnovesje med povpraševanjem in ponudbo, posebnosti pa sta tudi poraba in pridobivanje električne energije, na kar vplivajo vremenski pogoji. Porabo dodatno zaznamuje še del dneva, dan v tednu in letni časi. Tovrstni razlogi se kasneje odražajo v nenadnih dvigih cen in razlikovanju cen na treh različnih nivojih glede na časovni okvir (dnevni, tedenski in letni) (Weron, 2014). Lago in drugi (2018a) izpostavljajo, da se z večjim obsegom prevzemanja obnovljivih virov energije povečuje tudi odvisnost pridobivanja električne energije od vremenskih pogojev, s tem pa tudi stabilnost cen. Višja stopnja integriranosti obnovljivih virov energije v sistem povzroči na trgu spremembo vedenja deležnikov. Takšen način prinaša tudi več možnosti za znaten upad v pridobivanju in porabi energije, posledično se pojavijo neravnovesja med pridobivanjem in porabo energije, stabilnost sistema pa postane ogrožena. Pri npr. vetrni energiji se je slednje odražalo v nestabilnosti cen električne energije (Baldick, 2012), medtem ko se je pri sistemih, ki so temeljili na sončni energiji, to pokazalo v izrazitih skokih cen (Milstein in Tishler, 2015).

Za napovedovanje cen električne energije so avtorji uporabljali različne pristope in koncepte, kot so teorija iger, fundamentalna metoda, metoda zmanjšanih oblik, statistični modeli in metode strojnega učenja. Najbolj zanesljive rezultate so podale metode strojnega učenja in statistični modeli. Pri tem je treba izpostaviti, da so statistični modeli v linearnih napovedih



manj zanesljivi pri visoki frekvenci podatkov. Uporaba linearnih modelov bi bila za napovedovanje cen električne energije uporabna v primeru, ko bi iskali vzorce na tedenski ravni, in manj primerna, ko bi želeli podati napoved s podatki o ceni ob določeni uri (Weron, 2014). Strojno učenje predstavlja uporabo računalniških metod, pri katerih na podlagi izkušenj podajamo napovedi. V tem primeru izkušnje pomenijo pretekle informacije, ki so zbrane in analizirane. Ključnega pomena za kakovost napovednega modela nosita obseg in kakovost podatkovnega seta. Temelj strojnega učenja je zasnova napovedovalnega algoritma (Shavlik in drugi, 1990). Posebnosti gibanja cen električne energije so tako pri različnih deležnikih vzbudile zanimanje za njihovo napovedovanje. Z natančnim napovedovanjem se zmanjšajo tveganja, ki jih prinaša negotovo gibanje cen, medtem ko se ekonomski učinki za deležnike zvišajo. Namen trga električne energije pa je tudi zagotavljanje stabilnosti omrežja. Namreč znatno nihanje cen vpliva na ravnovesje omrežja, s tem pa tudi na možnost uporabe strateških rezerv in povečanje tveganja za izpad omrežja (Lago in drugi, 2018b).

Namen magistrskega dela je prikazati postopek izgradnje modela strojnega učenja, ki bo na osnovi analize gibanja ekonomskih parametrov in časovnih vrst omogočil napovedovanje cen električne energije v Sloveniji. S pomočjo tovrstnih modelov lahko podjetja, ki se ukvarjajo z distribucijo električne energije, sprejemajo informirane odločitve, ki vodijo do bolj učinkovitega poslovanja. Za doseganje namena magistrskega dela raziskava sledi naslednjim ciljem:

- na podlagi kritičnega pregleda literature preučiti dejavnike, ki so značilni na trg energentov,
- opisati metode napovedovanja, ki jih je mogoče uporabiti za napovedovanje cen električne energije,
- primerjati modele za napovedovanje gibanja cen električne energije,
- predstaviti postopek zbiranja in priprave podatkov ter izbor primernih metod za izgradnjo in ovrednotenje modelov za strojno učenje, s katerimi je mogoče napovedati gibanje cen električne energije,
- predstaviti potek izgradnje modela za napoved gibanja cen električne energije v Sloveniji s pomočjo strojnega učenja.

Pri pisanju magistrskega dela uporabim znanje, ki sem ga pridobila med podiplomskim študijem na Ekonomski fakulteti Univerze v Ljubljani. Uporabljena je deskriptivna metoda, metoda komparacije in statistične metode. Magistrsko delo je sestavljeno iz teoretičnega in praktičnega dela. V teoretičnem delu so na podlagi domače in tuje literature predstavljeni dejavniki, ki vplivajo na trg energentov, in dosedanje raziskave s področja podatkovne analitike na področju trgovanja z energenti. S pomočjo znanstvene in strokovne literature so podrobneje opredeljene značilnosti trga električne energije ter metode in tehnike napovedovanja. Empirični del se osredotoča na izgradnjo modela za strojno učenje, s katerim so napovedane cene električne energije. Vhodni podatki so pridobljeni iz različnih prosto dostopnih baz in poročil priznanih institucij. V programu za strojno učenje je zgrajenih več

napovedovalnih modelov, za katere so rezultati testirani in ovrednoteni. Nazadnje je opredeljen še pomen rezultatov za podjetja, ki se ukvarjajo z distribucijo električne energije.

Struktura magistrskega dela je naslednja: v prvem poglavju je predstavljen trg energentov, kjer je podrobneje opisano stanje energetskih virov članic EU, trgovanje z energenti in pomen podatkovne analitike na področju trgovanja z energenti. Drugo poglavje zajema predstavitev trga električne energije, ki je tudi predmet obravnave pričujočega magistrskega dela. V tretjem poglavju so predstavljene metode in tehnike napovedovanja s poudarkom na metodah strojnega učenja, s pomočjo katerih bo v četrtem poglavju zgrajen model za napovedovanje gibanja cen električne energije v Sloveniji. Hkrati četrto poglavje zajema pregled preteklega gibanja cen električne energije in opis metodologije. V petem poglavju je opredeljen doprinos ugotovitev za podjetja in opredelitev možnosti nadgradnje raziskave.

## **2 TRG ENERAGENTOV V EVROPSKI UNIJI**

EU na področju energetike stremi k zagotavljanju varne, cenovno dostopne in čiste energije za prebivalce in podjetja (European Commission, brez datuma). Gospodarski razvoj članic EU je odvisen od stalnega in zanesljivega dostopa do energetskih virov.

Za strukturo proizvodnje električne energije v EU je značilno, da so članice izrazito odvisne od uvoza fosilnih goriv za uporabo v elektrarnah (Kijewska in Bluszcz, 2016). V letu 2021 je bilo 41,3 % električne energije proizvedene iz fosilnih goriv, 24,3 % iz nuklearne energije, vetrna energija je prispevala 14,7 %, vodna 13,8 %, sončna 5,5 % in geotermalna 0,2 % ter ostali viri 0,2 % (Eurostat, 2023a). EU si v svojih ciljih za razvoj energetskega sistema prizadeva, da bi do leta 2030 k proizvodnji elektrike obnovljivi viri prispevali 45 %. Z integracijo obnovljivih virov energije želi EU doseči 55 % zmanjšanje izpustov emisij CO<sub>2</sub> do leta 2030 (Evropska komisija, 2022).

Večjo prelomnico za evropski energetski trg je predstavljalo sprejetje direktive za uvedbo enotnega elektroenergetskega trga leta 1996. Leta 1998 je bil sprejeta še direktiva za uvedbo enotnega trga za plin. Preoblikovan energetski trg je spodbudil diverzifikacijo in prilagodljivost na spremembe trga znotraj posamezne države. Hkrati se je izboljšala pogajalska moč pri pridobivanju energetskih virov zaradi širšega nabora dobavnih poti in lažjega dostopa do kupcev (Karan in Kazdağlı, 2011). Energetski trgi znotraj posameznih držav so bili pred tem vertikalno integrirani, z liberalizacijo in uvedbo konkurence pa so bila podjetja prisiljena k investiranju v napredne tehnologije in usmerjenosti v stroškovno učinkovitost. Na drugi strani so bili kupci deležni nižjih cen (Pepermans, 2019). Podjetja na veleprodajnem trgu so začela v večjem obsegu trgovati bilateralno in na borzah.

Nacionalni energetski trgi se precej razlikujejo z vidika uporabe primarnih virov za pridobivanje električne energije. Hkrati obstaja različna stopnja privzemanja obnovljivih virov energije, saj jim vse države niso naklonjene v enaki meri (Karan in Kazdađli, 2011).

## 2.1 Nafta

Surova nafta je spojina dvesto ali več različnih organskih spojin, večinoma alkanov. Vrsta nafte se določa glede na njen izvor (kje je bila pridobljena), običajno pa tudi glede na relativno težo. Razlikuje se tudi po vsebnosti žvepla, saj se po tem dejavniku določijo tudi potrebe po rafiniranju (Morales Pedraza, 2015a). Rafiniranje nafte zahteva operacije, kot so ločevanje nafte na različne frakcije, izboljševanje kakovosti in priprava mešanic (Favenec, 2022). Po drugi svetovni vojni so se začele dogajati večje spremembe v metodah pridobivanja nafte in v infrastrukturi. Leta 1960 je bila ustanovljena Organizacija držav izvoznic nafte (angl. Organization of the Petroleum Exporting Countries, v nadaljevanju OPEC), ki za svoje članice določa kvote za črpanje in cene nafte (Dibooglu in AlGudhea, 2007).

Ob koncu leta 2020 so se največje znane količine nafte nahajale v Venezueli, Savdski Arabiji, Kanadi, Iranu, Iraku in Kuvajtu. Z izjemo Kanade so vse države članice OPEC in skupaj posedujejo 70,1 % svetovnih zalog nafte. Z vidika dnevno načrpanih sodov nafte imajo največje Združene države Amerike (v nadaljevanju ZDA), sledita Savdska Arabija in Rusija. V tem pogledu imajo večji delež (65,3 %) države, ki niso članice OPEC (British Petroleum, 2021a).

EU je neto uvoznica surove nafte, saj je v večji meri odvisna od tujih virov. V letu 2020 je bila glavna partnerica pri dobavi Rusija, sledijo Norveška, Kazahstan, ZDA in Savdska Arabija. V zadnjih letih se struktura dobave spreminja. Predvsem se je zmanjšal uvoz iz Rusije, Iraka in Savdske Arabije, na drugi strani pa se je povečal uvoz iz Norveške, Kazahstana in ZDA. Med članicami EU so največje proizvajalke Italija, Danska in Romunija. EU se za vir uvoza odloča na podlagi različnih kriterijev, kot so cene, pogodbe, odločitve OPEC, mednarodnih pogojev, prevoznih stroškov ipd. Največji delež goriva se je porabil za izvajanje različnih oblik prevozov. Največji neto uvoz predstavljajo gorivo/dizel, nafta in utekočinjen naftni plin. EU je bila neto izvoznica motornega goriva in kurilnega olja (Eurostat, 2022a). Države članice morajo ohranjati zaloge naftnih derivatov za devetdeset dni vnaprej glede na povprečno porabo lanskega leta. Visoka odvisnost od uvoza virov predstavlja za EU določeno stopnjo ranljivosti glede oskrbe s fosilnimi gorivi. S tega vidika postajajo prizadevanja za nizkoogljično in energetsko učinkovito evropsko gospodarstvo še izrazitejša (Bredin in Muckley, 2011).

## 2.2 Premog

Gre za obliko fosilnega goriva, ki se pridobiva z nadzemnim ali podzemnim izkopavanjem. Nadzemno izkopavanje vključuje večjo stopnjo uporabe mehanizacije, zato velja za stroškovno učinkovitejši pristop. Podzemno rudarjenje se uporablja, ko se kamnina nahaja globlje pod površjem. Pri omenjenem načinu se običajno uporablja ena od naslednjih tehnik (Bhattacharyya, 2011):

- »prostora in stebra«, ki velja za delovno intenzivno in je primerna za manj globoke rudnike s tankimi plastmi premoga;
- »dolge stene«, ki velja za kapitalno intenziven način in se uporablja v globljih rudnikih.

V Evropi se pridobivata rjavi (pretežno lignit) in črni premog. Lignit je med premogi najmlajšega izvora in prinaša najmanjši izkoristek pri pridobivanju energije. V primerjavi z ostalimi vrstami premoga vsebuje lignit več vlage in najmanj ogljika. Posledično je izgorevanje manj učinkovito, obenem pa se ustvari več emisij CO<sub>2</sub> (Speight, 2021). Za proizvodnjo električne energije se običajno poleg lignita uporablja še bitumenski premog (črni premog), ki zaradi višje vsebnosti ogljika nudi boljši izkoristek (Euracoal, brez datuma a).

Pridobivanje črnega premoga v Evropi velja za ekonomsko neupravičenega zaradi pomanjkanja virov (Bhattacharyya, 2011). Uporaba premoga v državah EU se od leta 1990 zmanjšuje. Namreč v letu 2020 je bilo pridobljenih 56 milijonov ton črnega premoga, kar je 80 % manj kot 1990, ko se je premog proizvajal v 13 državah. Zaradi prehoda k drugim oblikam energije in sprememb v industriji se je med leti 1990 in 2020 poraba črnega premoga zmanjšala za 63 %. V letu 2020 je Poljska proizvedla 96 % premoga v EU. Največ rjavega premoga oziroma lignita (95 %) je proizvedenega v Nemčiji, na Poljskem, Češkem, v Bolgariji in Romuniji (Eurostat, 2021). Trgovina z lignitom se ni razvila, saj zaradi njegove nizke kaloričnosti transport na daljše razdalje ne bi bil ekonomičen. Posledično se večina lignita porabi v državi, kjer je pridobljen (Euracoal, brez datuma b).

Izvoženega je 15 % pridobljenega premoga. Avstralija, ki izvozi 40 % pridobljenega premoga, velja za največjo neto izvoznico, sledita Indonezija in Rusija (Morales Pedraza, 2015a).

Leta 2020 se je pretežni del rezerv nahajal (med 85 % in 90 %) v ZDA, Rusiji, Avstraliji, na Kitajskem in v Indiji (British Petroleum, 2021b). Premog velja za globalno dobro razširjeno surovino v primerjavi s plinom in surovo nafto, katerih 70 % zalog se nahaja v elipsi med severozahodom Sibirije do Kaspijskega jezera in Perzijskega zaliva. Posledično je možnost za njegovo dobavo stabilna. Trenutne zaloge surove nafte, urana in plina presegajo letno porabo od 40- do 70-krat, medtem ko zaloge premoga presegajo letno porabo za 150-krat in

zaloge lignita 200-krat. Torej bi ob nespremenjeni porabi lahko s trenutnimi zalogami surovine pokrivali potrebe še vsaj sto let (Thielemann in drugi, 2007).

Članice EU so v letu 2020 več kot polovico premoga uvozile iz Rusije, sledita ZDA in Avstralija. V istem letu je bilo 92 % rjavega in 49 % premoga porabljenega v termoelektrarnah in toplarnah (Eurostat, 2022b).

Premog velja za najbolj ogljično intenzivno obliko fosilnega goriva. Številne članice EU so začele zmanjševati proizvodnjo električne energije v termoelektrarnah, ki delujejo na premog. Dodatno je EU pospešila postopek dekarbonizacije z uvedbo sistema trgovanja s pravicami do emisij toplogrednih plinov (Böhringer in Rosendahl, 2022).

### **2.3 Zemeljski plin**

Tako kot surova nafta je zemeljski plin nastal z razgradnjo organskih snovi, ki so se razkrajale pod visokim tlakom v anaerobnih pogojih. Zemeljski plin je mešanica ogljikovodikov, predvsem metana ter manjših količin etana, propana in butana. Pogosto se nahaja skupaj z ostalimi fosilnimi gorivi na naftnih ali plinskih poljih (Speight, 2018).

Zemeljski plin ima največjo vrednost ogljikovodikov med tovrstnimi oblikami energetskih virov in posledično nudi največji izkoristek za pridobivanje električne energije (Economides in Wood, 2009).

Postopki pridobivanja so podobni kot pri črpanju nafte, pri čemer ločimo konvencionalni in nekonvencionalni način pridobivanja zemeljskega plina. Konvencionalni način pomeni, da je fosilno gorivo (nafta oziroma plin) v obliki, ki omogoča takojšnje črpanje. Pri tem se uporabljajo standardne metode, ki ne zahtevajo posebnih tehnologij in so cenejše. Nekonvencionalni viri so težko dostopni, njihovo pridobivanje poteka z lomljenjem kamnin globoko pod površjem zemlje (Speight, 2018).

Prednost fosilnih goriv je v možnosti shranjevanja in transporta večjih količin (Economides in Wood, 2009). Z možnostjo transporta zemeljskega plina na daljše razdalje se je povečalo zanimanje za njegovo uporabo. Poraba se je še zlasti povečala za namen pridobivanja električne energije, s tem pa je nadomestila uporabo premoga in nafte (Speight, 2018).

Zaradi težnje po zmanjševanju izpustov toplogrednih plinov je zemeljski plin v zadnjem času predstavljal ustrezno alternativo za proizvodnjo elektrike zaradi nižje ogljične intenzivnosti v primerjavi z ostalimi oblikami fosilnih goriv (Morales Pedraza, 2015a). Za termoelektrarne z delovanjem na zemeljski plin je značilen učinkovit izkoristek goriva, krajši čas, ki je potreben za načrtovanje in izgradnjo obrata, ter fleksibilnost delovanja, saj je potreben krajši čas za zagon in prekinitev delovanja elektrarne v primerjavi s termoelektrarnami, ki delujejo na premog. Predstavljajo tudi dopolnilni vir proizvodnje električne energije v primeru

nezadostne proizvodnje iz obnovljivih virov oziroma povečanega povpraševanja (Morales Pedraza, 2015a).

Evropski trg zemeljskega plina tvorijo proizvajalci, operaterji plinovodov, operaterji plinskih skladišč, podjetja za dobavo plina končnim odjemalcem. Poraba, ki je najvišja v zimskih mesecih, se običajno pokriva s črpanjem zalog. Obratno se v času manjšega povpraševanja skladišča polnijo za kasnejšo porabo (Egging in Gabriel, 2006). Kapacitete za hranjenje zemeljskega plina so razporejene neenakomerno, saj se izven Rusije in Belorusije največja skladišča v Evropi nahajajo v Ukrajini in Nemčiji. Glede na to, da nekatere članice EU hranijo plin v imenu drugih članic, bi imele slednje lahko težave z dostopom do zalog v primeru zmanjšane dobave plina (Di Bella in drugi, 2022).

Največ znanih virov zemeljskega plina se nahaja v Rusiji (19,9 %), sledita Iran (17,1 %) in Katar (13,2 %). Med evropskimi državami se največ zalog plina (0,8 %) nahaja na Norveškem (British Petroleum, 2021c). V članice EU so se največje količine zemeljskega plina v letu 2020 uvozile iz Rusije (23,3 %), Norveške (22,7 %), Ukrajine (10,2 %) in Belorusije (8,9 %). Treba je izpostaviti, da plin, ki je uvožen iz Ukrajine in Belorusije, običajno izhaja iz Rusije (Eurostat, 2022c).

Glede na visoko stopnjo odvisnosti Evrope od uvoza zemeljskega plina je stroškovno učinkovit način uvoza preko plinovodov, vendar slednje zahteva dolgoročne investicije v infrastrukturo, kar lahko postane kritično v primeru kriz (Hafner in drugi, 2008). Bredin in Muckley (2011) izpostavita, da je varnost in raznolikost dobavnih poti zemeljskega plina v Evropo nestabilna. Zaradi ponavljajočih se geopolitičnih trendov se EU zavzema za manjšo odvisnost od uvoza iz Rusije ter izboljšanje pripravljenosti na tveganja in infrastrukturnega omrežja znotraj Evrope.

## **2.4 Jedrska energija**

Klimatske spremembe in razpoložljivost fosilnih goriv sta v zadnjem času pripeljala do ponovnih obravnav o vrednosti jedrske energije. Po jedrski nesreči v Černobilu leta 1986 je bilo veliko pozornosti usmerjene na varnost tovrstnih elektrarn in na nevarnost jedrskih odpadkov. Posledično so številne države opustile načrte za gradnjo novih in se odločile za zapiranje obstoječih jedrskih elektrarn (Pampel, 2011). Dodatne predsodke o varnosti jedrskih elektrarn je vzbudila nesreča v Fukušimi leta 2011, kar je vodilo do zapiranja nekaterih elektrarn v Evropi (Morales Pedraza, 2015b).

Med pomembnejšimi razlogi za ohranjanje jedrskih elektrarn je pričakovano višanje cen fosilnih goriv in težnja po manjšanju izpustov emisij CO<sub>2</sub>, k čemur se je EU zavezala s Kjotskim protokolom. Tretji razlog je odvisnost Evrope in še zlasti članic EU od uvoza fosilnih goriv iz politično nestabilnih držav srednjega vzhoda in Rusije.

Jedrska energija nastane ob cepitvi ali zlivanju atomskih jeder. Proizvajanje električne energije v jedrskih elektrarnah je stroškovno konkurenčno ostalim načinom z izjemo elektrarn v državah z višjimi zalogami fosilnih goriv. Stroški goriva za jedrske elektrarne predstavljajo manjši delež celotnih proizvodnih stroškov, vrednosti dolgoročnih investicij so višje kot pri termoelektarnah. Jedrske elektrarne imajo nizke stroške obratovanja, a visoke stroške zagona in izklapljanja elektrarne, zato se uporabljajo kot osnovni vir za pridobivanje električne energije (Morales Pedraza, 2015b).

Za delovanje jedrskih elektrarn se uporablja uranova ruda, ki je na voljo v omejenih količinah. Članice EU so odvisne od uvoza iz Kanade, ZDA, Avstralije, Gabona in Nigra. Omenjene države so zanesljive dobaviteljice, saj nobena izmed naštetih držav ne dominira na trgu (Van Hecke, 2007).

Po podatkih Eurostata (2022č) je bilo leta 2020 v jedrskih elektrarnah EU proizvedene 25,2 % manj električne energije kot 2006. Razlog je predvsem v 61,5 % zmanjšanju proizvodnje električne energije v jedrskih elektrarnah v Nemčiji. Največ električne energije, proizvedene v jedrskih elektrarnah v EU, prispeva Francija (51,8 %), sledijo Nemčija, Španija in Švedska. Od evropskega trenda opuščanja jedrskih elektrarn odstopa šest držav, ki so med leti 2006 in 2020 povečale proizvodnjo električne energije v jedrskih elektrarnah (Romunija, Nizozemska, Češka, Slovenija in Finska). Večji del zalog urana se nahaja v državah Organizacije za gospodarsko sodelovanje in razvoj (angl. Organisation for Economic Co-operation and Development, v nadaljevanju OECD) (44 %), 22 % v Braziliji, Rusiji, Indiji, Kitajski in Južni Afriki (BRICS) in 34 % v ostalih državah sveta. Viri z nizkimi stroški pridobivanja zadoščajo predvidoma za naslednjih sto let ob trenutnem obsegu povpraševanja.

## **2.5 Obnovljivi viri energije**

Med obnovljive vire energije štejemo tiste vire, ki se konstantno obnavljajo skozi naravne procese in jih ne bo zmanjkalo. Obnovljive vire energije predstavljajo energija sonca, biomasa, voda in veter in geotermalna energija. Omenjeni viri služijo za pridobivanje elektrike, toplote in goriva.

Večje zanimanje za obnovljive energetske vire se je pojavilo v sedemdesetih letih prejšnjega stoletja zaradi rasti cen nafte. Posledično so države ob zavedanju klimatskih sprememb več resursov začele namenjati raziskavam na obravnavanem energetskega področju. Uvajanje uporabe obnovljivih energetskega virov je vplivalo na stabilnost dobave in trgovanje z električno energijo ter na zasnovo elektroenergetskega sistema.

Biogorivo se pridobiva iz različnih rastlinskih virov. V Evropi se za pridobivanje biogoriva uporabljajo rastline z visoko vsebnostjo rastlinskega olja (predvsem oljna repica in sončnice).

Električna energija, pridobljena iz obnovljivih virov, ima določene tehnične posebnosti, saj viri niso konstantno na voljo v enakem obsegu. Hkrati mora biti ob dejstvu, da električne energije ni možno učinkovito shranjevati, električna energija iz teh virov porabljena v trenutku, ko je na voljo. Slednje zaradi nekonstantnosti proizvodnje predstavlja številne težave. Posledično električna energija ne more biti dostavljena po pričakovanjih. Kljub temu se z napovedovanjem vremenskih pogojev izboljšuje tudi ocena pričakovane proizvodnje električne energije iz obnovljivih virov. Hkrati je treba imeti zaradi nezanesljive proizvodnje na voljo še rezervne kapacitete, ki običajno uporabljajo neobnovljive vire (Bhattacharyya, 2011).

Goldemberg (2004) izpostavi na primeru pridobivanja električne energije iz obnovljivih virov poleg ugodnih okoljskih vplivov in zmanjšanja emisij CO<sub>2</sub> še varnost dobave, izboljšanje dostopa do energije, zaposlitvene priložnosti. Hkrati izboljšuje makroekonomsko stabilnost zaradi zmanjšanja odvisnosti od uvoza energentov, s čimer se gospodarstvo lahko izogne možnosti gospodarskega šoka zaradi zunanjih dejavnikov.

V Evropi se delež električne energije, pridobljene iz obnovljivih virov, glede na primarni vir razlikuje med državami. V EU je bilo leta 2020 iz obnovljivih virov energije proizvedenih 37,5 % vse porabljene električne energije. Največ prispevata vetrna (36 %) in vodna energija (33 %), sledi sončna (14 %) in trda biogoriva (8 %). Med članicami največ električne energije iz obnovljivih virov proizvede Avstrija (78,2 %), najmanj pa Malta (9,5 %) (Eurostat, 2023b).

## **2.6 Trgovanje z energenti**

Prva terminalska pogodba za nakup nafte na trgu energentov je bila sklenjena leta 1978 na Newyorški blagovni borzi (NYMEX). S tem se je začelo trgovanje z energenti, ki mu je med leti 1980 in 1990 sledila uvedba terminskih pogodb za plin in nafto. Naftna podjetja in finančne hiše zagotavljajo podjetjem likvidnost pri trgovanju, saj lahko trgujejo na terminskih borzah, reguliranih s strani državnih organov, ali na trgu izvedenih finančnih instrumentov, ki se obračunavajo na terminskih borzah (Fusaro, 2005).

Trg energentov zaznamujejo določene posebnosti, kot so elastičnost ponudbe in povpraševanja, zahtevnost dobave in prenosa, možnost shranjevanja in možnost uporabe substituta. Omenjeni dejavniki vplivajo na trg energentov z organizacijskega in pogodbenega vidika ter oblikovanja cen (Hafner in Luciani, 2022). Značilnosti posameznih vrst energentov se med seboj razlikujejo, s tem pa se razlikujejo tudi načini trgovanja. Trgu električne energije služi fizično omrežje, ki zahteva konstantno stabilnost proizvodnje in porabe (Kirschen in Strbac, 2004). Zahtevi po stalni usklajenosti ponudbe in povpraševanja sledi tudi hitro spreminjanje cen. Posledično se je trg prilagodil z uvedbo trgovanja s kratkoročnimi produkti, kot so 15-minutne avkcije (Hafner in Luciani, 2022). S tega vidika se razlikuje od trgovanja s plinom, ki lahko v večjih količinah ostane shranjen v plinovodu.



Neuskklajenost ponudbe in povpraševanja bi morala biti v primeru zemeljskega plina dolgotrajnejša, preden bi prišlo do znatnejših težav omrežja. Neuravnoteženost se v tem primeru lahko popravi s tržnimi mehanizmi (Kirschen in Strbac, 2004). Hafner in Luciani (2022) za trg plina izpostavita, da znotraj dobavne verige potekajo različni načini trgovanja. Trgovanje z dolgoročnimi pogodbami ostaja prevladujoč način na mednarodnih trgih. Cena na trgu se lahko oblikuje na podlagi nihanja cen nafte (angl. oil indexation) ali glede na povpraševanje in ponudbo (angl. hub indexation).

Med vsemi energenti največ trgovanja poteka z nafto, katere cena pogosto odraža svetovne ekonomske razmere. Delovanje svetovnega naftnega trga poteka na specifičen način, saj ima kakovost posameznih derivatov precejšen vpliv na njihovo ceno. Pri tem trgovanje poteka na osnovi sklicevanja na določena fizična merila, katerih lastnosti se skozi čas spreminjajo. Delovanje fizičnega trgovanja je odvisno tudi od tipa dostave. Zaradi zaščite pred morebitnimi zamudami v dobavi so se začeli uporabljati izvedeni finančni instrumenti, s tem pa se je razvil terminski trg, kjer se trguje s »papirnimi« sodčki (Hafner in Luciani, 2022). Različni naftni trgi se med seboj povezujejo na osnovi enakih vrst nafte, s katerimi se pogosto trguje, in s tem tvorijo svetovni naftni trg. Posebnost naftnega trga je, da prevladuje trgovanje z naftnimi derivati, surova nafta pa se dobavlja na osnovi dolgoročnih pogodb po referenčni ceni za posamezno vrsto nafte (Imsirovic, 2022). V začetku je večji del trgovanja potekal na promptnem trgu, ki se je razvil zaradi strukturnih sprememb panoge v sedemdesetih letih prejšnjega stoletja in zaradi potrebe po diverzifikaciji virov ponudbe in povpraševanja. Promptni trg služi različnim namenom, med drugim določi končno ceno surove nafte in naftnih derivatov ter nudi alternativni kanal za trgovanje z nafto.

V primerjavi z ostalimi fosilnimi gorivi poteka s premogom manj trgovanja. Namreč 82 % premoga se porabi v državi, kjer je izkopen (Fernández Alvarez, 2022). Med razlogi za nizko stopnjo trgovanja so zahtevnost in stroški prevoza surovine (Bhattacharyya, 2011). Trgovanje s premogom je v preteklosti veljalo za zahtevnejše v primerjavi z drugimi surovinami zaradi več vrst različne kakovosti (premoga). Potreba po liberalizaciji trga električne energije in potreba po zaščiti pred tveganji je povzročila razvoj finančnih instrumentov (Fernández Alvarez, 2022). Zaradi omejitev, vezanih na transport, sta se razvila dva trga (Bhattacharyya, 2011):

- atlantski, kjer so glavne uvoznice zahodno evropske države (Nemčija, Velika Britanija, Španija),
- pacifiški, kjer so glavne uvoznice Japonska, Južna Koreja in Kitajski Tajpej.

Večji del trgovanja se izvede na pacifiškem trgu, predvsem zaradi strožjih okoljskih omejitev.

V želji po omejevanju izpustov toplogrednih plinov je EU leta 2005 uvedla sistem za trgovanje z emisijskimi kuponi. Posamezen emisijski kupon podjetju daje pravico do izpusta

ene tone CO<sub>2</sub>. V prvi fazi so države med podjetja razdelile emisijske kupone na podlagi nacionalnega načrta omejevanja izpustov emisij CO<sub>2</sub> (Marcu in Cecchetti, 2022). Podjetja se lahko odločijo za investicije v projekte za zmanjšanje izpustov CO<sub>2</sub> v državah v razvoju ter preostanek emisijskih kuponov prodajo na trgu. V primeru prekoračitve dovoljene količine izpustov CO<sub>2</sub> pa morajo podjetja emisijske kupone kupiti. Trgovanje lahko poteka na borzi v obliki terminskih in promptnih poslov ali bilateralno (Mäntysaari, 2015).

## **2.7 Podatkovna analitika na področju trgovanja z energenti**

Podatkovna analitika pomaga podjetjem do sprejemanja odločitev na podlagi dejstev (Camm in drugi, 2020). Bigliani (2013) izpostavi, da je za energetska podjetja ključni izziv upravljanje z informacijami. Zato skušajo najti načine za uporabo tehničnih in poslovnih podatkov v strukturirani in nestrukturirani obliki. Podatkovna analitika nudi podjetjem različne možnosti uporabe, med drugim tudi napovedovanje gibanja cen. Na podlagi združevanja podatkov iz različnih virov podjetja lahko pridobijo širše razumevanje trga (Pospiech in Felden, 2016).

Podjetja, ki trgujejo z energenti, optimizirajo prihodke na podlagi napovedovanja proizvodnje, povpraševanja in cen. Poleg napovedovanja obsega proizvodnje podjetja pri trgovanju z energenti analizirajo trende na področju cen in povpraševanja ter na ta način oblikujejo načrt za trgovanje na borzi (Mathiesen in drugi, 2013). Napovedovanje cen pomaga odločevalcem pri oblikovanju portfelja in načrtovanju naložb. Na drugi strani operaterji lahko na podlagi predvidenega gibanja cen naredijo izračune indeksov in meril za spremljanje trga.

Wu in drugi (2021) izpostavijo pomembnost pravilnega napovedovanja cen surove nafte za države proizvajalke in uvoznice, saj lahko na ta način razvijejo stabilno zakonodajo in načrtujejo potrebna sredstva. S pomočjo obdelave masovnih podatkov in tekstovnega rudarjenja je možno iskati razloge za gibanje cen.

V trenutni obliki veleprodajnega trga električne energije cene odražajo visoko volatilitnost, s čimer so proizvajalci in odjemalci izpostavljeni finančnim tveganjem. Iz tega razloga se podjetja odločajo za uporabo sistemov za napovedovanje cen za prilagajanje v kratkem času. V ta namen sistem potrebuje raznolike informacije o vremenu, cenah goriv in zmogljivosti prenosnega omrežja med območji. Zahtevnost napovedovanja se povečuje zaradi integracije obnovljivih virov energije v omrežje (Kardoš in drugi, 2021).

Namen podatkovne analitike v obravnavanem kontekstu je torej iskanje priložnosti za trgovanje. Več o metodah in tehnikah podatkovne analitike je predstavljeno v tretjem poglavju magistrskega dela.

### **3 TRG ELEKTRIČNE ENERGIJE**

Elektroenergetska panoga velja za kapitalno intenzivno panogo z dolgimi obdobji prilagoditve v proizvodnji. Med razlogi, ki predstavljajo visoke ovire za vstop v panogo, so tudi negotovost prihodnjih cen in dolga obdobja, ki so potrebna za izgradnjo novih kapacitet (Larsen in Bunn, 1999). Delovanje trga se mora prilagajati tudi fizičnim značilnostim elektrike. Namreč elektrike ni možno učinkovito shranjevati, odjemalci pa je ne morejo razlikovati po načinu proizvodnje, zato na veleprodajnem trgu velja za homogen produkt. Zaradi omrežnih omejitev morata biti proizvodnja in poraba električne energije konstantno usklajeni, čemur se udeleženci trga lahko prilagodijo z napovedovanjem povpraševanja in ponudbe. Trgovanje z električno energijo poteka glede na napovedano porabo, zato so produkti diferencirani glede na časovni okvir. Trgovanje poteka s fizičnimi in finančnimi pogodbami, ki se sklepajo na letni, četrtletni ali mesečni ravni ter za dan vnaprej oziroma znotraj dneva. Produkt z najkrajšim časom med trgovanjem in dobavo se imenuje izravnalna energija. Ločimo bilateralno trgovanje in trgovanje na borzi (Creti in Fontini, 2019).

Ob preučevanju geografskega vidika elektroenergetskih trgov je treba v ozir vzeti zmogljivost omrežij. Države s slabimi elektroenergetskimi omrežji so manj primerne za vključevanje v spajanje trgov. Pred integracijo trgov pomemben del predstavlja analiza primernosti dveh trgov. S teoretičnega vidika se trga lahko integrirata, ko elastičnost povpraševanja ponudnikom onemogoča, da bi ceno elektrike dvignili nad konkurenčno raven. Zaradi skorajšnje homogenosti električne energije zakon ene cene lahko obvelja (Böckers in drugi, 2013).

#### **3.1 Trgovanje z električno energijo**

Na trgu sodelujejo proizvajalci, trgovci in dobavitelji električne energije. Proizvajalci in dobavitelji morajo vnaprej oddati ponudbe in povpraševanje. Presečišče krivulj ponudbe in povpraševanja nato določi tržno ceno in urnik dobave elektrike (Prabavathi in Gnanadass, 2015). Trgovanje lahko poteka bilateralno (angl. over the counter, v nadaljevanju OTC) ali na borzah. Z namenom uravnoteženja proizvodnje električne energije sistemski operaterji trgujejo še na izravnalnem trgu. Na ta način lahko na podlagi vnaprej določenih cen uravnotežijo proizvodnjo ali porabo. Na promptnem trgu poteka trgovanje za dan vnaprej in znotraj dneva, ki temeljita na ponudbah za nakup in prodajo znotraj vsake ure ter za naslednjih štiriindvajset ur. Trgovanje poteka za dan vnaprej, pri čemer obratovalni načrt določi sistemski operater (Creti in Fontini, 2019).

##### **3.1.1 Promptni trg**

Trgovanje za dan vnaprej poteka na borzi in temelji na zbiranju ponudb in povpraševanj. Deluje na način avkcijskega trgovanja, kjer presečišče ponudbe in povpraševanja predstavlja končno ceno. Osnovno trgovanje predstavlja trgovanje z urnimi pogodbami za naslednjih

štiriindvajset ur. Pri trgovanju z bločnimi produkti dobavitelj določi fiksno količino in ceno ter del dneva, za katerega bo daljše obdobje dobavljal energijo (Shah in Chatterjee, 2020). Tovrsten način trgovanja zagotavlja učinkovitost trga, saj se glede na pričakovano povpraševanje določi, katere elektrarne bodo proizvajale in dobavile potrebne količine (Cervigni in Perekhodtsev, 2013). Omenjeni pristop je posebej primeren za termoelektrarne, ki imajo visoke stroške zagona in ugašanja (Shah in Chatterjee, 2020). Obravnavani način trgovanja omogoča proizvajalcem z omejenimi možnostmi za hitre prilagoditve dovolj časa za prilagoditev ter poda dokaj točno napoved povpraševanja in razpoložljivosti elektrarn. Cene na trgu za dan vnaprej pogosto zaznamuje nihanje, zato podjetja poskušajo električno energijo zakupiti za čim daljše časovno obdobje na terminskem trgu (Green, 2008).

Proces trgovanja vključuje (BSP Energetska borza d. o. o., brez datuma a):

- fazo trgovanja, ko kupci in proizvajalci lahko oddajo ponudbe oziroma povpraševanja;
- fazo mirovanja, znotraj katere nadzornik trgovanja odkriva morebitne nepravilnosti;
- fazo po trgovanju, ki določi marginalno ceno in količino električne energije za vsako uro naslednjega dne;
- neaktivno fazo za pregled lastnih poslov.

Stanje ponudbe in povpraševanja se lahko po zaključenem trgovanju spremeni. Proizvajalci in dobavitelji lahko pred dejansko dobavo naknadno usklajujejo stanje s trgovanjem na znotraj dnevnem trgu (Cervigni in Perekhodtsev, 2013).

Znotraj dnevno trgovanje poteka na način stalnega trgovanja z različnimi energetskeimi pogodbami, ki se sklenejo, ko so na presečišču ponudbe in povpraševanja. Podjetja trgujejo z urnimi, petnajstminutnimi in blok produkti. Udeleženci trga pa lahko usklajujejo pogodbe do najmanj ene ure pred dospeljem. Znotraj dnevno trgovanje pomaga kupcem pri prilaganju na nepričakovane spremembe v proizvodnji in porabi električne energije (Shah in Chatterjee, 2020). Znotraj dnevno trgovanje nastopi po zaključku trgovanja za dan vnaprej. Po tipu interakcije med kupcem in prodajalcem se znotraj dnevno trgovanje deli na sprotno in avkcijsko trgovanje, ki velja kot dopolnitev trgovanja za dan vnaprej in ima določeno enotno ceno. Za sprotno trgovanje, ki poteka štiriindvajset ur dnevno, je značilno, da se ponudbe in povpraševanje usklajujejo brez avkcij, dogovor pa se sklene s prvim kupcem (Shinde in Amelin, 2019). Henriot (2012) izpostavi, da se udeleženci odločijo za sprotno trgovanje predvsem v primeru želje po pravočasnem zmanjšanju cenovnih tveganj. Slabša plat omenjenega načina trgovanja je nezmožnost učinkovitega načrtovanja, saj je posel sklenjen s prvim kupcem, ki sprejme ponudbo (angl. First-come-first-serve principle). Podjetja se pogosto odločijo za trgovanje na znotraj dnevnem trgu, saj jim ta omogoča uravnoteženje stroškov (evropski trgi so temu močno izpostavljeni). Podjetja lahko uravnotežijo lastno proizvodnjo in porabo energije (Scharff in Amelin, 2016). Trgovanje znotraj dneva se konča eno uro pred fizično dobavo in se nadaljuje s trgovanjem na izravnalnem trgu, kjer udeleženci trgujejo samo še z operaterjem prenosnega sistema (Agencija Republike

Slovenije za energijo, 2021). Znotraj dnevni trg pridobiva veljavo zaradi povečane uporabe obnovljivih virov energije, ki imajo manjšo konsistentnost pri zagotavljanju proizvodnje električne energije. Razpoložljivost slednjih se lažje napove bližje dejanski dobavi elektrike (Mäntysaari, 2015).

### 3.1.2 Izravnalni trg

Ohranjanje stabilnosti elektroenergetskega sistema je z liberalizacijo postalo kompleksnejše. Posledično morajo deležniki na trgu električne energije podati jasno informacijo o proizvodnji in porabi električne energije ter sistemskemu operaterju omogočati uravnoteženost sistema.

Izravnalni trg služi za ohranjanje ravnotežja elektroenergetskega sistema. Operater omrežnega sistema ima možnost nakupa ali odprodaje izravnalne energije v realnem času na mejah prenosnega omrežja s sosednjimi sistemskimi operaterji (Pravila za izvajanje izravnalnega trga z elektriko, 2014), Ur. l. RS, št. 97/14, 28/17 in 161/22. Ponudbe, ki so oddane v trgovanju znotraj dneva, lahko operater prenosnega sistema sprejme kot ponudbe na izravnalnem trgu. Posledično so to posli, namenjeni izravnavi odstopanj na elektroenergetskem sistemu. Ločimo posle, ki se izvajajo v okviru trgovanja znotraj dneva, in posle, sklenjene na izravnalnem trgu (Agencija Republike Slovenije za energijo, 2021). Na izravnalnem trgu se trguje s petnajstminutnimi produkti, urnimi produkti, standardiziranimi bloki urnih produktov in poljubnimi bloki produktov, ki jih ponudnik definira sam (Pravila za izvajanje izravnalnega trga z elektriko, 2014). Na večini izravnalnih trgov se uporablja enotna cena, ki je nato zaračunana deležnikom zaradi neuskkljenosti. Cena predstavlja razliko med pogodbenim (proizvodnja električne energije, dolgoročne pogodbe in vsota trgovanj) in dejanskim stanjem (Green, 2008).

### 3.1.3 Terminski trg

Cramton (2017) pripisuje terminskemu trgu pomembno vlogo za stabilizacijo cen elektrike. Ta obenem omogoča kupcem nakup energije vnaprej, s čimer lahko zmanjšajo tveganje. Udeleženci trga morajo podati ponudbe in povpraševanje vnaprej, saj proizvajalci na ta način lahko učinkoviteje zagotavljajo dobavo energije. Na drugi strani terminski trg za kupce predstavlja tudi način za upravljanje tveganja, ki je prisoten na borzi zaradi volatilnosti cen električne energije (Anderson in drugi, 2007). Pogodbena trgovanja med proizvajalci in dobavitelji so prevladujoč način terminskega trgovanja, trgovanje pa poteka tudi med proizvajalci električne energije. Terminske pogodbe vključujejo fizično in finančno poravnavo. Fizična poravnava določa, da se proizvajalec zaveže k dobavi določene količine električne energije po določeni ceni v določenem prihodnjem obdobju. V kolikor proizvajalec ne zagotovi zadostne količine, jo mora kupiti na borzi. Finančna poravnava ureja področje plačevanja. S terminskimi pogodbami si kupci zagotovijo dobavo električne energije po terminski ceni. V kolikor se za dospelost določi krajše obdobje (en dan ali ena

ura vnaprej) se sklenejo fizične pogodbe. Na razmerje cene elektrike med borzo in bilateralnim trgom vplivajo zaloge plina kot primarnega vira za proizvodnjo električne energije (Douglas in Popova, 2008).

Ločimo standardizirane in nestandardizirane pogodbe ter izvedene finančne instrumente. Za standardizirane pogodbe (angl. Futures) je značilno, da imajo natančno opredeljena določila pogodbe, kraj trgovanja, transakcijske zahteve in izravnalne postopke. Samo trgovanje poteka na borzi, zaradi česar je cenovno tveganje nižje, poslovanje pa bolj transparentno. V večini so standardizirane pogodbe izvedene s plačili in ne fizično dostavo, kar pomeni, da so transakcijski stroški nižji. Kreditno tveganje je manjše pri standardiziranih pogodbah, saj nestandardizirane pogodbe zajemajo strožje zahteve pri maržah, s čimer se zagotavlja finančna sposobnost vseh udeležencev na trgu. Slabost standardiziranih pogodb izhaja iz rigidnosti in omejenega obsega transakcij.

Pri nestandardiziranih pogodbah (angl. Forwards) se v primerjavi s standardiziranimi trguje z večjimi količinami električne energije. Nestandardizirano trgovanje se izvaja kot OTC. Slednje predstavlja finančno bolj tvegan način trgovanja, saj se plačila izvajajo ob dospelosti, medtem ko poravnava standardiziranih pogodb poteka dnevno (Deng in Oren, 2006). Ob nizkem zanimanju za trgovanje z nestandardiziranimi pogodbami proizvajalci lahko zvišajo cene na dnevnem trgu in s tem spodbudijo kupce k bilateralnemu trgovanju.

Zamenjave so izvedeni finančni instrument, kjer gre za tip finančne pogodbe, s katero deležnika določita fiksno ceno električne energije ne glede na spreminjajoče se cene na trgu za dan vnaprej oziroma za fiksno ceno v določenem časovnem obdobju. Predstavljajo način za zagotavljanje kratko- do srednjeročne cenovne stabilnosti. Zamenjave so oblika nestandardiziranih pogodb, ki vključujejo več poravnav in za vsako izmed njih enako ceno. Z osnovnimi zamenjavami se stranki dogovorita za fiksno ceno dobave elektrike na drugo lokacijo, kot je bila določena s standardizirano pogodbo. Imetnik osnovne zamenjave se s tem zaveže, da bo prejel ali plačal razliko med ceno, ki se določi s pogodbo in ceno na lokalnem promptnem trgu (Deng in Oren, 2006).

Naslednji izvedeni finančni instrument so t. i. opcije, ki se uporabljajo za zaščito pred cenovnimi tveganji. Nakupna opcija nudi imetniku pravico do nakupa električne energije po vnaprej določeni ceni do izteka opcije. Prodajne opcije nudijo enako pravico do prodaje. Največkrat se z opcijami trguje na bilateralnem trgu. Uporabljajo se tudi »Spark spread option«, ki omogočajo pokrivanje razlike med ceno prodane električne energije in ceno surovine, ki je bila potrebna za proizvodnjo (Deng in Oren, 2006).

#### 3.1.4 Bilateralni trg

Gre za obliko prostovoljnega trga med proizvodnimi podjetji kot prodajalci in trgovci ter kupci. V primeru zmanjšane proizvodnje sta vlogi lahko zamenjani. Ker pogosto prihaja do

razlik med dogovorjeno in dejansko dobavljeno količino, sistemski operater izvaja še izravnalni trg. Slabost omenjenega načina trgovanja je, da ni povpraševanja in ponudbe v realnem času (Barroso in drugi, 2005).

### **3.2 Oblikovanje cen električne energije**

V času, ko je bil trg električne energije še vertikalno integrirana panoga, kjer so regulatorji določili ceno na podlagi proizvodnje, prenosa in distribucijskih stroškov, so cene veljale za zelo stabilne. Po prestrukturiranju elektrogospodarstva se je z vstopom na trg povečala konkurenca v proizvodnji in ponudbi. Proizvajalci konkurirajo v prodaji električne energije, medtem ko dobavitelji kupujejo električno energijo na trgu/borzi po ceni, ki jo določi presečišče agregirane ponudbe in povpraševanja. Liberalizacija je med drugim prinesla deregulacijo cen, kar je vplivalo na njihovo volatilnost (Escribano in drugi, 2011).

Na volatilnost cen električne energije vplivajo omejitve proizvodnih kapacitet, slabe čezmejne zmogljivosti, nekonsistentno povpraševanje in proizvodnja elektrike iz naravnih virov ter nihanja cen emisijskih kuponov in fosilnih goriv (Moffatt Associates Partnership, 2008). Poglavitni razlog za nihanje cen elektrike predstavlja nezmožnost njenega učinkovitega shranjevanja in potreba po stalni uravnoveženosti proizvodnje in potrošnje. Povpraševanje po elektriki je neelastično, saj velja za nujno surovino, obenem pa je podvrženo tudi vremenskim vplivom. Ob nizkem povpraševanju proizvajalci dobavljajo elektriko z uporabo enot, ki imajo nižje marginalne stroške, saj so večje količine potrebne za proizvajalce z višjimi marginalnimi stroški, ko ti vstopijo v sistem. Intenzivnost povpraševanja, nihanje cen in omejitev ponudbe ob večjem povpraševanju ustvarja volatilnost kratkoročnih cen (Escribano in drugi, 2011). Na cene električne energije vplivajo tudi vremenski pogoji. Verjetnost za večje skoke v cenah je izrazito sezonska, saj je povpraševanje večje poleti in pozimi (Cartea in Figueroa, 2005). Serati in drugi (2008) dodajajo tudi tedensko in dnevno komponento. Pomemben dejavnik nihanja cen je tudi pridobivanje energije iz obnovljivih virov. Z večjo stopnjo prevzemanja obnovljivih virov energije se je povečala tudi odvisnost proizvodnje elektrike glede na vremenske razmere (Lago in drugi, 2018a). V primeru pridobivanja energije z vetrnimi elektrarnami je bilo ugotovljeno, da se volatilnost poveča z večjim obsegom prevzemanja vetrnih elektrarn (Green in Vasilakos, 2010). Milstein in Tishler (2015) izpostavita, da je nihanje cen pogostejše z večanjem pridobivanja električne energije iz sončnih elektrarn.

Eden izmed dejavnikov je tudi primarni vir, potreben za proizvodnjo električne energije. Jacobs in drugi (2017) izpostavijo, da je glavna surovina za pridobivanje elektrike še vedno zemeljski plin, katerega cena je posledično tesno povezana tudi s cenami elektrike. Cena zemeljskega plina, ki ga uporabljajo elektrarne, vpliva na cene elektrike v daljšem časovnem obdobju (na mesečni in letni ravni). Cene premoga imajo manjši vpliv. Srednjeročno ima na dnevni in tedenski ravni največji vpliv povpraševanje in dajatve na ceno. Na kratko časovno obdobje (znotraj ure) imajo vpliv morebitni izpadi in težave pri prenosu energije. Nihanje

cen fosilnih goriv povzroči spremembo načina trgovanja na veleprodajnem trgu, kar negativno vpliva na stabilnosti cen električne energije (Chu in drugi, 2017). Nekateri trgi proizvajalcem omogočajo spremembo oddanih ponudb pod določenimi pogoji. Torej proizvajalci, ki niso zavezani trgovanju za dan vnaprej, lahko spremenijo način trgovanja in se udeležijo izravnalnega trga. Višji vstopni stroški omejujejo proizvajalce na prilagajanje ponudb, s tem pa se volatilitnost poveča. Na drugi strani je volatilitnost cen električne energije manjša, ko so portfelji proizvajalcev odvisni od ponudnikov z nižjimi vstopnimi stroški (podjetja, ki pridobivajo zemeljski plin) (Reguant, 2014).

Cena elektrike se razlikuje tudi med posameznimi državami, saj imajo te različne stroške, povezane z omrežji in elektrarnami. Pri obravnavanju omrežnih težav je posebno pozornost treba posvetiti možnim preobremenitvam in potencialnim tehničnim težavam, ki bi lahko vodile do izpada sistema. Povpraševanje na trgu električne energije je neelastično, vendar se povečana poraba električne energije odraža tudi v cenah. Znatne spremembe v povpraševanju povzročijo vključevanje dražjih energetskih virov, kar se prelije tudi v cene. Torej večji obseg porabe pomeni večji obseg proizvodnje, kar povzroči višje mejne stroške proizvodnje, ki bodo rastle eksponentno glede na vir, ki je potreben za proizvodnjo elektrike (nuklearna ali hidroelektrarna ali surovina – plin, premog, gorivo) (Howison in Coulon, 2009).

Trgi električne energije so odvisni od lokalnih pogojev, kar se odraža tudi v cenah. V odvisnosti od naravnih virov lahko proizvodnja električne energije poteka z uporabo fosilnih goriv (zemeljski plin, premog, gorivo), medtem ko se drugje v večji meri zanašajo na obnovljive vire (veter, sonce, geotermalna, biomasa ...) ali nuklearne zmogljivosti.

Omejitve omrežij in prenosa energije preprečujejo prenos energije med širše razporejenimi geografskimi območji. Slednje vpliva na odvisnost cen in pogodb od lokalnih dejavnikov, ki se kažejo v ponudbi in povpraševanju (stanje elektrarn, vremenski in klimatski pogoji, poraba elektrike). Dodatno vplivata tudi struktura posameznega trga in zakonodaja (Jacobs in drugi, 2017). Goto in Karolyi (2004) dodatno izpostavita vlogo zasnove trga. Kot dejavnike omenjata cenovno elastičnost povpraševanja, kapacitete proizvajalcev, strukturo lastništev, proizvodnjo tehnologije, organiziranost borze (ali je sodelovanje prostovoljno ali obvezno), cenovno politiko in prenosni trg ter obliko avkcij.

Po uvedbi emisijskih kuponov so prodajalci električne energije začeli dodajati strošek slednjih tudi marginalnim stroškom proizvodnje. Dodajanje vrednosti stroška CO<sub>2</sub> povečuje cene na veleprodajnem trgu in ustvarja »davek« za proizvodnjo električne energije z visokim ogljičnim odtisom. Strošek emisijskih kuponov ima vpliv na cene na terminskem trgu, medtem ko je imel na dnevnem trgu vpliv zgolj ob uvedbi (Jouvet in Solier, 2013).



### 3.3 Zasnova trga električne energije

#### 3.3.1 Udeleženci na trgu z električno energijo

Tradicionalni elektroenergetski sistemi so temeljili na manjšem številu proizvajalcev, ki so se nahajali v bližini energetskega vira. Prenos je potekal na obsežnih geografskih območjih po omrežju neposredno do odjemalcev. Po deregulaciji panoge so se na trgu začeli pojavljati novi udeleženci. Kategorije niso medsebojno izključujoče, saj lahko posamezen udeleženec deluje na več področjih (Kirschen in Strbac, 2004). Kategorije so predstavljene v nadaljevanju (Biggar in Hesamzadeh, 2014; Kirschen in Strbac, 2004; Skantze in Ilic, 2001):

- proizvajalci električne energije so podjetja, ki posedujejo zmogljivosti za pridobivanje električne energije iz različnih primarnih virov energije (fosilna goriva, sončna, vetrna in vodna energija). Proizvajalci so do različnih stopenj vključeni na veleprodajnem trgu. S tem sodelujejo na trgu pri določanju cene in prevzemajo priporočila za obseg proizvodnje;
- distributer je lastnik in skrbnik distribucijskega omrežja. Na prostih trgih je prodaja elektrike končnim uporabnikom ločena od upravljanja, razvoja in vzdrževanja distribucijskega omrežja;
- prenosno omrežje zagotavlja prenos visokonapetostne električne energije med večjimi proizvajalci in distribucijskimi omrežji;
- distribucijsko omrežje zagotavlja prenos nizkonapetostne električne energije večjemu številu odjemalcev;
- neodvisni sistemski operater ohranja fizično varnost elektro energetskega sistema. Skrbeti mora za uravnoteženost energije in primerno obremenitev omrežja;
- operater trga z električno energijo zbira in usklajuje ponudbe za nakup in proizvodnjo ter skrbi za poravnavo poslov. Med drugim skrbi, da trgovanje poteka transparentno in na način, ki ohranja elektroenergetski sistem stabilen;
- trgovec z električno energijo kupuje električno energijo na veleprodajnem trgu in jo prodaja končnim odjemalcem. Nekateri trgovci se ukvarjajo tudi s proizvodnjo, prenosom in distribucijo. Na podlagi pričakovanega povpraševanja oddajo povpraševanje in s tem zagotovijo dobavo zadostne količine električne energije;
- regulator je nacionalni organ, ki zagotavlja učinkovito in transparentno delovanje elektroenergetskega sektorja. Določa cene monopolnih storitev in produktov.

#### 3.3.2 Oblike elektroenergetskih trgov

Vertikalno integrirana podjetja so v preteklosti izvajala vse aktivnosti znotraj elektroenergetskega sistema, saj so imela v lasti proizvodne zmogljivosti, prenosna in distribucijska omrežja, s tem pa tudi monopol na določenem geografskem območju. V kolikor bi bila dva elektroenergetskega sistema povezana, bi sistem upravljalo eno, vertikalno integrirano podjetje skupaj s sistemskim operaterjem povezanega sistema.

Vertikalno integrirane panoge ne slonijo nujno na enem podjetju, a deležniki sodelujejo na podlagi pravnih ali pogodbenih dogovorov kot ena sama entiteta. Podjetja tako ustvarijo monopol. Potrošniki so v takšnih okoliščinah bolj podvrženi izkoriščanju, zato se v namen zagotavljanja učinkovitosti cene regulirajo (Cretì in Fontini, 2019).

Hkrati je običajno eno podjetje imelo tudi vlogo systemskega operaterja in operaterja distribucijskega omrežja. Po liberalizaciji je trgovanje začelo potekati na energetskih borzah. Tako so se na trgu začeli pojavljati novi proizvajalci, ki so med drugim uporabljali tudi cenovno ugodnejše vire za pridobivanje električne energije. Dodatno se je z liberalizacijo trga začelo medregijsko povezovanje trgov, kar je zaradi dostopa do več kapacitet zagotavljalo boljše stabilnost omrežja. Vendar je medregijsko povezovanje svoj popolni namen doseglo šele z uvedbo promptnega trga. Z uvedbo veleprodajnega trga se je začelo pojavljati trgovanje v realnem času. Cretì in Fontini (2019) ločita poleg monopola še tri načine organiziranosti trga električne energije: model z izključnim kupcem, veleprodajni trg ter vzporedno prisotnost veleprodajnega in maloprodajnega trga.

**V modelu z izključnim kupcem** so lahko vse ali samo nekatere elektrarne v lasti več neodvisnih proizvajalcev električne energije. Izključni kupec ima vlogo systemskega operaterja, operaterja distribucijskega omrežja in dobavitelja. Lahko nastopa na trgu tudi kot proizvajalec. V obravnavanem modelu se redkeje srečujemo s prisotnostjo samo enega lastnika elektrarn in ne več neodvisnih proizvajalcev. V tem primeru bi tržna struktura delovala na način bilateralnega monopola. V vertikalno integrirani panogi je tovrsten način prvi korak k ustvarjanju konkurence na trgu. Odvzemanje proizvodnih kapacitet lahko poteka na tri načine (Cretì in Fontini, 2019):

- odvzemanje lastništva, kjer so elektrarne prodane podjetjem, ki na novo vstopijo na trg. Izvede se kot zasebni sporazum ali kot javni razpis. Namen je ustvariti konkurenco med proizvajalci in enim kupcem;
- pogodbeno sodelovanje med proizvajalcem primarnega goriva in lastnikom elektrarne, ki se zaveže, da bo proizvajal električno energijo za vnaprej določeno plačilo;
- v primeru virtualnih elektrarn lastnik le-teh dodeli kupcu pravico do upravljanja proizvodnih kapacitet. Pogodba mora vključevati ceno, po kateri je pravica do upravljanja prodana, in kako se bo določala cena proizvedene električne energije.

Vzpostavitev modela z enim kupcem omogoča izmenjavo električne energije med elektrarnami in »enim kupcem«. Sodelovanje urejajo pogodbeni dogovori med obema stranema in določajo pogoje za proizvodnjo električne energije in plačilo.

Na **vleprodajnem trgu** je že prisoten systemski operater in operater distribucijskega sistema, ki je prej nastopal kot izključni kupec. Veleprodajni trg predstavlja stičišče ponudbe in povpraševanja.

Veleprodajni trg, kjer distributerji kupijo električno energijo pri proizvajalcih. Na tej stopnji organiziranost trgovanja poteka na dva načina (Creti in Fontini, 2019):

- preko borze, kjer morajo sodelovati neodvisni proizvajalci električne energije;
- promptni trg, kjer proizvajalci in kupci trgujejo z energijo pred dejansko dobavo.

Oba načina trgovanja sta centralizirana, kar pomeni, da ima pregled nad delovanjem sistemski operater oziroma operater trga. Proizvajalci lahko sodelujejo tudi na bilateralnem trgu, ko je promptni že zaključen. Z vidika drobnoprodajnega trga distributer kupuje električno energijo v imenu končnih odjemalcev in skrbi za distribucijsko omrežje. Na ta način okolje panoge postane bolj konkurenčno na strani proizvajalcev. Cena se določi na stičišču ponudbe in povpraševanja. Kljub temu maloprodajna cena ostaja regulirana, saj končni odjemalci ne morejo sami izbrati dobavitelja. Distribucijska podjetja so s tem bolj izpostavljena nenadni rasti cen električne energije. Na veleprodajnem trgu končni kupci niso prisotni, saj distributerji kupujejo električno energijo v njihovem imenu. V nadaljnjih korakih odpiranja trga so prisotni nekateri večji odjemalci, ki so povezani neposredno na distribucijsko omrežje. Kupcu se s tem ni treba zanašati na distributerja, s čimer se trg približa popolni liberalizaciji (Kirschen in Strbac, 2004).

Ob prisotnosti **maloprodajnega trga** govorimo o popolnoma liberaliziranem trgu. Posamezne naloge med proizvodnjo in dobavo električne energije se razdelijo med več akterjev in niso več omejene na proizvodnjo in prenos, temveč tudi distribucijo in prodajo. Vloga distribucijskih podjetij se razdeli med operaterje distribucijskega omrežja in več dobaviteljev električne energije končnim kupcem. Osnovni namen maloprodajnega trga je ustvarjanje konkurence, ki pa najbolje deluje, ko je znotraj distribucijskega omrežja prisotnih več dobaviteljev električne energije. Dobavitelji električne energije lahko združijo povpraševanje in pridobijo električno energijo na različne načine, ki jih omogoča trg, ter dobavijo električno energijo končnim odjemalcem. Na drugi strani lahko kupci samostojno izbirajo dobavitelje električne energije oziroma samostojno nastopajo na veleprodajnem trgu (Creti in Fontini, 2019). Kupci lahko sami izbirajo med več dobavitelji, ki električno energijo kupujejo na veleprodajnem trgu. Distribucijska podjetja na ta način izgubijo monopol z vidika ponudbe električne energije. Kljub temu naravni monopol tvori ostaja na strani prenosnih in distribucijskih omrežij. Na tej stopnji maloprodajna cena ni več regulirana, saj lahko kupci sami izberejo dobavitelja. Cene se določajo na podlagi interakcije med ponudbo in povpraševanjem. Strošek distribucije in prenosa se prenese na končnega odjemalca (Kirschen in Strbac, 2004).

Kirschen in Strbac (2004) izpostavita še uvedbo nabavne agencije ob prehodu iz monopola. Omenjena oblika predstavlja prvi korak k ustvarjanju konkurence, saj proizvajalec energije ni več lastnik vseh kapacitet od proizvodnje do dobave. Neodvisni proizvajalci dobavijo električno energijo prodajnemu agentu. Nadaljnje v tej fazi razvoja trga prvotno vertikalno integrirano podjetje ni več proizvajalec električne energije, temveč le-to kupuje pri

neodvisnih proizvajalcih. Distributerji skrbijo za dobavo elektrike kupcem. Na tej stopnji morajo biti cene še vedno regulirane, saj ima nabavna agencija monopol nad distributerji.

### **3.4 Slovenski trg električne energije**

Slovenski elektroenergetski sistem je bil do leta 1991 vertikalno integriran, v tem letu pa so se aktivnosti razdelile med osem proizvodnih in pet distribucijskih podjetij ter eno prenosno podjetje. Obseg proizvodnje električne energije je potekal glede na dnevni načrt, ki ga je pripravilo prenosno podjetje (ELES). Električna se je prodajala na podlagi kratkoročnih dogovorov med proizvajalci, prenosnim podjetjem in distribucijskimi podjetji (Hrovatin in drugi, 2009). Delovalo je pet distribucijskih podjetij, ki so imela dovoljenje za dobavo električne energije znotraj posamezne regije in so s tem ustvarjala monopol na tem območju. Dobiček se je razdelil med posamezna podjetja glede na njihove stroške. Na ta način so hidroelektrarne, ki obratujejo z nizkimi stroški, lahko sofinancirale termoelektrarne, katerih obratovalni stroški so višji. S tem so se ohranjale nižje cene za končne odjemalce (Filippini in drugi, 2004). Vlada je regulirala cene električne energije, saj je slednja predstavljala dobroto, ki bi morala biti dostopna vsem prebivalcem. Posledično prihodki niso pokrivali stroškov pridobivanja in distribucije električne energije. Med drugim je vlada po osamosvojitvi s pomočjo regulacije cen omejevala visoko inflacijo (Filippini in drugi, 2004).

Slovenija se je s pridobitvijo naziva kandidatke za članico EU zavezala k uskladitvi zakonodaje na ravni EU. Leta 1999 je bil sprejet Energetski zakon, ki je pripomogel k ustvarjanju konkurenčnega trga z električno energijo in plinom ter vzpostavitvi nadzora nad delovanjem trga. Cilj reform je bil med drugim povečanje konkurence na strani proizvodnje in dobave ter oblikovanje trga na način, ki omogoča trgovanje z električno energijo. Dejavnosti prenosnega in distribucijskih podjetij so ostale regulirane zaradi prisotnosti naravnega monopola. Energetski zakon je določal tudi ustanovitev reguliranega dostopa tretjega deležnika za električno omrežje. Agencija RS za energijo deluje neodvisno in izvaja nadzor nad delovanjem trga. Med drugim so se z energetskim zakonom definirale regulirane in neregulirane dejavnosti, kar je pomagalo k bolj transparentnemu financiranju.

Postopno odpiranje trga je potekalo med leti 2001 in 2007. Sprva je bil vzpostavljen notranji trg, s čimer so do proste izbire dobavitelja postali upravičeni odjemalci s priključno močjo 41 kW na enem odjemnem mestu. Na trg so se vključili tudi trgovci, posredniki in zastopniki (Agencija Republike Slovenije za energijo, 2001) V drugi stopnji odpiranja trga so možnost vstopa na trg dobila tuja podjetja. Trg je bil polno odprt, ko je bila prosta izbira dobavitelja omogočena gospodinjsvom.

Pomemben element k ustvarjanju enotnega evropskega trga električne energije je tudi medregijsko povezovanje. Slovenski trg se na trgu znotraj dneva povezuje z avstrijskim, italijanskim in hrvaškim. V okviru trga za dan vnaprej je vključen pri spajanju na mejah z Avstrijo, Italijo in Hrvaško (Agencija Republike Slovenije za energijo, 2021). V letu 2021

je bila Slovenija glede na izmenjave električne energije neto izvoznica na meji z Italijo in uvoznica na meji z Avstrijo in Hrvaško. Upoštevajoč, da polovica proizvedene električne energije v Nuklearni elektrarni Krško pripada Hrvaški, je bila Slovenija leta 2021 neto uvoznica. Zgolj z vidika izmenjave električne energije na mejah s sodelujočimi sosednjimi državami je bila Slovenija lani neto izvoznica.

Hrovatin in drugi (2009) izpostavijo, da vsi cilji reform niso bili izpolnjeni. Koncentracija proizvodnih in prodajnih podjetij ostaja visoka, kar se kaže kot posledica majhnega slovenskega trga. Avtorji dodajo, da je bil cilj države zaščititi slovenske proizvajalce bolj kot vzpostavitev konkurence. Posledično je večina elektrarn ostala v državni lasti, saj so se v letu 2001 združile v holding (HSE). Klopčič in drugi (2022) izpostavljajo, da je v primeru visoke koncentracije treba oblikovati strožja pravila, ki spodbujajo konkurenčnost, in omogočiti neodvisnim proizvajalcem dostop do trga.

V letu 2021 je bilo največ električne energije proizvedene v Nuklearni elektrarni Krško (37,5 %), sledijo elektrarne, ki kot primerni vir za proizvodnjo energije uporabljajo obnovljive vire s 36,7 % (vodna energija, sončna energija, biomasa in vetrna energija). Najmanj energije je bilo proizvedene v elektrarnah na fosilna goriva (25,8 %) (Agencija Republike Slovenije za energijo, 2022).

Leta 2001 je na slovenski trg vstopil organizator trga z električno energijo (Borzen), katerega naloga je bila povečanje konkurenčnosti na trgu in izboljšanje učinkovitosti veleprodajnega trga. Hkrati je služil kot vstopna točka za tuja podjetja in je pospeševal regionalno integracijo trgov v jugovzhodni Evropi (Bojnc in Papler, 2019). Borzen je hkrati lastnik borze SouthPool, ki pravnim in fizičnim osebam s pravico do sodelovanja omogoča trgovanje znotraj dneva za dan vnaprej na izravnalnem trgu in dolgoročnih avkcijah za fizične produkte (BSP Energetska borza d. o. o., brez datuma b). Na borzi SouthPool je v letu 2021 sodelovalo sedem domačih in pet tujih udeležencev. Na trgu za dan vnaprej je v letu 2021 sodelovalo 20 udeležencev, od tega večji del tujih (Agencija Republike Slovenije za energijo, 2022).

Slovenski elektroenergetski trg usklajuje razvojne cilje s smernicami, ki jih določa EU. Zavzema se za zmanjšanje uvoza fosilnih goriv, zmanjšanje izpustov CO<sub>2</sub> in prehod na obnovljive vire energije. Dodatno je cilj vzpostavitev stabilnega in naprednega elektroenergetskega trga (Klopčič in drugi, 2021).

## **4 METODE IN TEHNIKE PODATKOVNE ANALITIKE ZA NAPOVEDOVANJE PRIHODNJIH DOGODKOV**

Napovedovanje prihodnjih dogodkov pomaga pri sprejemanju racionalnih odločitev (Armstrong, 2001). Od tod sledi, da je napovedovanje cen električne energije postalo ključni del odločevalskega mehanizma za elektroenergetska podjetja. Zaradi visokih nihanj cen se

morajo podjetja pri trgovanju zavarovati pred cenovnimi in količinskimi tveganji. Z napovedovanjem cen za različna časovna obdobja lahko elektrarne prilagodijo obseg proizvodnje električne energije, dobavitelji pa trgovalne načrte (Weron, 2014). Poleg uspešnejšega poslovanja podjetij napovedovanje cen pripomore tudi k stabilnosti elektroenergetskega omrežja (Lago in drugi, 2018b).

Na odločitev za izbiro napovedne metode vpliva več dejavnikov. Abraham in Ledolter (1983) omenita želeno stopnjo natančnosti modela, časovni okvir napovedovanja, višino stroška, ki je sprejemljiva za pripravo napovedi, stopnjo kompleksnosti in razpoložljivost podatkov. V nadaljevanju sledi opis metod napovedovanja, kot jih opredeli Weron (2014). Običajno se uporabljajo na trgu električne energije.

#### **4.1 Statistične metode**

Bistvo statističnega napovedovanja je prilagajanje modela situaciji in ekstrapolacija modela na prihodnje dogodke (Gilchrist, 1974). Napovedi, ki temeljijo na matematičnih ali statističnih modelih, uvrščamo med kvantitativne in se lahko nadaljnje delijo na deterministične in stohastične (Abraham in Ledolter, 1983). V determinističnih modelih so podatki izraženi v obliki matematičnih funkcij, kot so linearni trendi, stohastični modeli pa temeljijo na različnih načinih opisovanja razmerij med sosednjimi opazovanji. Značilno je, da vključujejo ključne komponente, ki se običajno opišejo z uporabo statistične verjetnosti (Gilchrist, 1974). Temelj kvantitativnih napovednih metod so zgodovinski podatki in napovedni model (Majid in Mir, 2018).

Pristop h kvantitativnemu napovedovanju sestoji iz dveh faz. Prva faza je namenjena izdelavi napovednega modela na podlagi ustreznih podatkov in teorije. V primerih, ko teorija ni ustrezna, je treba uporabiti historične podatke za oblikovanje modela. V drugi fazi, fazi napovedovanja, pa je treba zagotoviti, da model in parametri ostanejo nespremenjeni. Stabilnost modela se lahko oceni na podlagi napovedi z novimi opazovanji (Abraham in Ledolter, 1983).

Statistične modele, ki jih naredimo s podatki, pridobljenimi na podlagi opazovanj, imenujemo empirični modeli. Napovedovanje z eno spremenljivko poteka na podlagi zgodovine časovne serije in jo ekstrapoliramo v prihodnost. Regresijsko napovedovanje se izvaja z uporabo razmerja med napovedno spremenljivko in pojasnjevalnimi spremenljivkami. Običajno regresijski modeli merijo takojšnje učinke, vendar lahko napovedna spremenljivka na odzivno spremenljivko deluje z zapoznelim učinkom. V tem primeru lahko razmerja preučujemo s kombinacijo regresije in modeli časovnih vrst (Abraham in Ledolter, 1983).

Najpogosteje uporabljena statistična tehnika napovedovanja je regresija. Cilj multiple regresije je odkrivanje povezav med več neodvisnimi ali napovednimi spremenljivkami ter

odvisno ali kriterijsko spremenljivko. Multipla regresija predpostavlja, da je razmerje med spremenljivkama linearno (Weron, 2014).

## **4.2 Metode strojnega učenja**

Namen strojnega učenja je razvoj algoritmov, ki posnemajo človeško inteligenco. Izhaja iz različnih disciplin, med drugim umetne inteligence, verjetnosti, statistike, računalništva in informacijske teorije, hkrati pa vključuje družboslovni vidik s področja psihologije in filozofije (El Naqa in Murphy, 2015). Alpaydin (2020) poleg obdelave podatkov v ospredje postavi tudi umetno inteligenco. Da je sistem lahko inteligen, mora imeti v spreminjajočem okolju možnost učenja. V kolikor se je sistem zmožen prilagajati dinamičnemu okolju, oblikovalcu sistema ni treba predvidevati rešitev vseh možnih izidov.

Alpaydin (2020) opredeli strojno učenje kot delovanje računalniškega programa z namenom optimizacije parametrov modela na podlagi učnih podatkov ali preteklih izkušenj. Ločimo napovedne modele, ki so usmerjeni v prihodnost, in deskriptivne modele, s pomočjo katerih pridobimo novo znanje o uporabljenih podatkih. Za izgradnjo matematičnih modelov strojno učenje uporablja teorijo o statistiki. Strojno učenje ima dve vlogi. Prva je učenje, kjer potrebujemo učinkovite algoritme za optimizacijo problema ter shranjevanje in obdelavo podatkov. V drugi fazi ovrednotimo model ne zgolj na podlagi točnosti napovedovanja, ampak tudi glede njegove smiselnosti in učinkovitosti.

Večina algoritmov strojnega učenja je zmožna obdelati obsežne baze podatkov. V ta namen so vključene tudi izpeljane funkcije, ki jih vključimo v postopku predprocesiranja in s tem izboljšamo zmogljivost modela (Badillo in drugi, 2020).

Glede na vrsto podatkov lahko strojno učenje razdelimo na nadzorovano, delno nadzorovano in nenadzorovano učenje (El Naqa in Murphy, 2015). Nadzorovano učenje se uporablja za izboljševanje algoritmov z namenom natančnejšega razvrščanja in napovedovanja. Uporablja učne podatke za izboljševanje modela z namenom, da bi podal želene rezultate (IBM, brez datuma). Glavni kategoriji nadzorovanega učenja sta razvrščanje v primeru, da imamo kategorične spremenljivke, in regresija v primeru numeričnih spremenljivk (Badillo in drugi, 2020). Nenadzorovano učenje se nanaša na izgradnjo modela po analizi podobnosti med vstopnimi podatki (de Mello in Ponti, 2018). Računalnik identificira še nepoznane vzorce na podlagi podatkov, znotraj katerih skupine še niso ustvarjene (Badillo in drugi, 2020).

## **4.3 Modeli za napovedovanje gibanja cen električne energije**

Weron (2014) opredeli pet metod napovedovanja cen električne energije, in sicer: modeli z več agenti, statistične metode, strojno učenje, fundamentalne metode in metoda zmanjšanih oblik. Pogosto se pri oblikovanju modela za napovedovanje cen uporabljajo hibridne rešitve,

ki vključujejo več tehnik napovedovanja. Glede na časovni horizont napovedovanja cen električne energije ločimo kratkoročno, srednjeročno in dolgoročno napovedovanje. V primeru kratkoročnega napovedovanja le-ta poteka za nekaj minut ali dni vnaprej. Srednjeročno napovedovanje se nanaša na od nekaj dni do nekaj mesecev vnaprej, dolgoročno pa od nekaj mesecev do nekaj let vnaprej. Različni horizonti napovedi služijo podjetjem za različne namene; tako je ključna vloga kratkoročnega napovedovanja zagotavljanje dnevnega delovanja trga, srednjeročno napovedovanje služi za upravljanje tveganj, določanje cen derivatov in izračun bilance, medtem ko se na podlagi dolgoročnega napovedovanja ugotavlja donosnost investicij.

Napovedovanje cen je skozi leta postalo kompleksnejše. V začetku so podjetja napovedovala cene za srednje in dolgoročno časovno obdobje na podlagi predvidenega obsega povpraševanja in načrtovane proizvodnje. Modeli, ki so temeljili na stroških, so napovedovali cene za posamično uro. S tem je bilo strateško vedenje in izvajanje tržne moči zapostavljeno. Tovrstne metode lahko delujejo na trgih z regulirano ceno, kjer je stopnja negotovosti nizka. Modeli z več agenti posnemajo delovanje heterogenih agentov v medsebojni interakciji. Ena izmed oblik so ravnotežni modeli, ki so primerni, ko ne razpolagamo s podatkom o zgodovini cen, poznamo pa stroške dobave in stanje konkurence (Weron, 2014).

Fundamentalni modeli obravnavajo osnovne fizične in ekonomske dejavnike, ki veljajo za proizvodnjo in trgovanje z električno energijo. Kristiansen (2011) izpostavi, da se s fundamentalno analizo iščejo razlogi za gibanja cene na podlagi podatkov o vremenu, razpoložljivosti elektrarn, načrtovanih vzdrževanjih, stanju omrežja, pričakovanega povpraševanja ipd.

Weron (2014) ugotavlja, da so modeli, ki preučujejo fundamentalne spremenljivke, pogosto zgrajeni s statističnimi tehnikami, strojnim učenjem ali metodo zmanjšanih oblik. Pri napovedovanju cen električne energije se fundamentalni dejavniki pojavljajo kot vhodne spremenljivke v regresijah ali nevronske mrežah. Fundamentalni podatki se zbirajo za tedenski ali mesečni okvir, zato so modeli primernejši za srednjeročne napovedi. Fundamentalni modeli se pogosteje uporabljajo za dolgoročno napovedovanje cen električne energije. Ziel in Steinert (2018) izpostavita uporabo v primeru preučevanja regulatornih sprememb na gibanje cene električne energije.

Cilj metode zmanjšanih modelov ni natančno napovedovanje cen znotraj vsake ure, ampak ponavljanje glavnih značilnosti dnevnega gibanja cen, med drugim korelacij med cenami surovin in cenami elektrike. Na tovrstnih modelih temelji oblikovanje sistemov za obvladovanje tveganj, razviti pa so bili za modeliranje obrestnih mer. V primeru, da cenovni procesi ne odražajo glavnih lastnosti cen elektrike, bo model podal napačne rezultate (Weron in Misiorek, 2006). Metoda zmanjšanih oblik se uporablja za napovedovanje dnevnih cen. Obenem daje dobre rezultate v primeru volatilitnosti.



Statistično napovedovanje se je sprva uporabljalo za napovedovanje povpraševanja po električni energiji, čemur je sledilo napovedovanje cen. Napovedovanje cen s statističnimi metodami temelji na uporabi matematične kombinacije preteklih cen in prejšnjih oziroma trenutnih eksogenih dejavnikov, kot so podatki o proizvodnji, porabi in vremenu. Med statističnimi metodami izstopajo multiplikativne in aditivne metode. Razlikujeta se glede na to, ali je napovedana cena vsota števil komponent ali produkt števil faktorjev. Natančnost napovedovanja je odvisna od učinkovitosti algoritma, kakovosti podatkov in možnosti vključitve podatkov o fundamentalnih dejavnikih. V primeru večjih nihanj statistične metode ne dajejo dobrih rezultatov, še zlasti, če model temelji zgolj na podatkih o preteklih cenah. V tem primeru se izstopajoče vrednosti z različnimi pristopi nadomestijo z drugimi vrednostmi. Prednost statističnih metod je v možnostih razlage, saj interpretacijo lahko povežemo s komponentami. Avtor kot pogosto uporabljene izpostavi metodo eksponentnega glajenja, regresijske modele, avtoregresivne modele časovnih vrst in modele splošne avtoregresivne pogojne heteroskedastičnosti (Weron, 2014).

Z metodami strojnega učenja lahko zgradimo modele na podlagi nelinearnih in kompleksnih razmerij (Aggarwal in drugi, 2009). Gre za pristop, ki se lahko prilagaja dinamičnim sistemom, zaradi česar so primerni za kratkoročne napovedi. Statistični modeli podajo dobre napovedi na tedenski ravni, ko so frekvence podatkov nizke. V primeru napovedovanja za posamezno uro, kjer je značilno nelinearno gibanje, pa je frekvenca podatkov previsoka in prekompleksna za napovedovanje (Amjady in Hemmati, 2006). Posledično so se v ta namen začele uporabljati metode strojnega učenja (Lago in drugi, 2018b). Za napovedovanje cen električne energije se pogosto uporabljajo nevronske mreže in metoda podpornih vektorjev (angl. support vector machine, v nadaljevanju SVM). Kljub temu boljša prilagodljivost na nelinearno gibanje ne daje nujno boljših napovedi.

Lago in drugi (2018a) v primerjavi statističnih metod in metod strojnega učenja ugotovijo, da zanesljivejše napovedi cen električne energije za dan vnaprej podajo modeli globokih nevronske mreže (angl. deep neural network, v nadaljevanju DNN) in ponavljajočih se nevronske mreže (angl. recurrent neural network, RNN), kot so modeli dolgotrajnega kratkoročnega spomina (angl. long short-term memory, v nadaljevanju LSTM) in zapornih ponavljajočih se enot (angl. gated recurrent unit, v nadaljevanju GRU). Pri tem DNN podajo boljše rezultate, vendar LSTM in GRU podata boljše napovedi pri določenih urah. Omenjene metode uvrščamo med globoke strukture in jih uporabljamo na kompleksnih, nelinearnih podatkih, pri čemer sta modela GRU in LSTM posebej primerna za delo s časovnimi vrstami. Avtorji pojasnijo, da omenjeni modeli potrebujejo večji obseg podatkov, da so lahko ustrezno učeni, ampak ima DNN v primerjavi z LSTM in GRU manj parametrov in je zato model lažje učiti. Avtorji primerjajo še konvolucijsko nevronske mreže z algoritmom ekstremnega gradientnega spodbujanja (angl. extreme gradient boosted trees, v nadaljevanju XGBoost) in SVR, pri čemer slednji podata boljše rezultate, saj se CNN slabše izkaže v primeru visoko koreliranih podatkov. Dodatno avtorji primerjajo statistične metode z

metodami strojnega učenja, pri čemer dajejo prednost zadnjim, saj v primeru nelinearnih podatkov potrebujemo nelinearne modele, če želimo zanesljive napovedi.

Weron (2014) izpostavi, da so nevronske mreže manj primerne za kratkoročno napovedovanje cen zaradi daljšega časa, ki je potreben za učenje modela. Posledično bi glede na hitro spreminjanje cen električne energije lahko dobili manj zanesljive napovedi. Hkrati je cena električne energije časovno odvisna, zaradi česar lahko rezultati nevronske mreže sčasoma postanejo slabši. Slednje pomeni, da se s časom lahko zgodijo drugačne stvari od predvidenih glede na preteklost, kar lahko povzroči slabše rezultate. Kljub temu, da so metode strojnega učenja bolj primerne za delo z nelinearnimi podatki, pa je izbira mrežne strukture in parametrov v večji meri odvisna od izkušenj avtorja (Cerjan in drugi, 2013).

Lago in drugi (2018a) kot potencialno metodo napovedovanja cen izpostavijo SVM. Yan in Chowdhury (2014) pri srednjeročnem napovedovanju cen z metodo SVM ugotavljata, da so rezultati modela močno odvisni od izbire spremenljivk. Avtorja kot prednost v primerjavi z nevronskimi mrežami izpostavita robustnost modela, ki pa ima na drugi strani manj možnosti za prilagajanje parametrov. Sansom in drugi (2003) ugotovijo, da pri napovedovanju cen električne energije SVM poda bolj konsistentne rezultate v primerjavi z NN.

González in drugi (2015) so za preučevanje vpliva povpraševanja in obsega proizvodnje električne energije glede na vir za ceno in napoved cene za dan vnaprej uporabili metodo združevanja »bootstrap« in naključnega gozda, ki temeljita na odločitvenih drevesih. Pri tem ugotovijo, da metoda naključnega gozda poda primerljive rezultate s statističnimi metodami. V primerjavi z naključnim gozdom XGBoost poda bolj točno funkcijo izgube in se bolj zanesljivo izogne pretiranemu prilagajanju na podatke. Prednost XGBoost je tudi kratek čas izgradnje modela in manjša kompleksnost modela (Xie in drugi, 2022).

Cerjan in drugi (2013) izpostavijo, da se za kratkoročno napovedovanje cen električne energije najpogosteje uporabijo metode časovnih vrst, umetne inteligence in hibridne metode. Med metodami časovnih vrst najpogosteje uporabijo avtoregresijski integrirani proces drsečih sredin (v nadaljevanju ARIMA), splošno avtoregresivno pogojno heteroskedastičnost (angl. Generalized Autoregressive Conditional Heteroskedasticity, v nadaljevanju GARCH) in dinamično regresijo.

Weron (2014) omenja še metodo avtoregresije in drsečega povprečja ter metodo avtoregresijskega procesa drsečih sredin (v nadaljevanju ARMA). Slednja predvideva, da so preučevani podatki (tedensko) stacionarni, v kolikor to za podatke ne drži, jih je treba preoblikovati v stacionarno obliko, kar lahko dosežemo z diferenciacijo. Metoda, s katero lahko to dosežemo, je metoda ARIMA, ki poleg avtoregresije in drsečih povprečij vključuje še diferenciacijo. Avtor doda, da so avtoregresijski modeli temelj modelov časovnih vrst, pri čemer za napovedovanje cen električne energije poudari pomen vključevanja meteoroloških podatkov in podatkov o obsegu povpraševanja. Amjadi in Hemmati (2006) poudarita, da

metode časovnih vrst, kot je ARIMA, podajo dobre napovedi ob stacionarnih podatkih. Garcia in drugi (2005) pri napovedovanju cen za dan vnaprej primerjajo metodi GARCH in ARIMA ter ugotovijo, da GARCH poda natančnejše napovedi za obdobja, ko je značilno visoko nihanje cen električne energije.

Jonsson in drugi (2012) za napovedovanje cen električne energije uporabijo metodo Holt-Winters. Avtorji kot prednost metode izpostavijo robustnost, kar pomeni, da znatnejši skoki cen ne vplivajo na napoved, saj metoda za napoved ne uporabi eksplicitno preteklih vrednosti. Cruz in drugi (2011) ugotovijo, da ARIMA poda točnejše rezultate pri kratkoročnem napovedovanju cene, medtem ko je pri srednjeročnem napovedovanju zanesljivejša metoda Holt-Winters.

Avtorji se pogosto odločajo za napovedovanje s hibridnimi modeli, saj na ta način lahko združijo linearne in nelinearne možnosti modeliranja. Pri hibridnih metodah gre za združevanje različnih napovednih metod z namenom premostitve šibkosti posamezne metode in ugotavljanja različnih vzorcev znotraj podatkov (Cerjan in drugi, 2013). Kljub temu so Lago in drugi (2018a) ugotovili, da hibridni modeli pogosto ne podajo boljših rezultatov kot modeli, narejeni s posamezno metodo. Dodatno Anbazhagan in Kumarappan (2014) pri napovedovanju cen za dan vnaprej izpostavita praktični vidik napovednih metod, pri čemer ugotovita, da hibridne metode potrebujejo več časa za izgradnjo modela, kar bi lahko predstavljalo težavo podjetjem pri dejanski rabi.

Rezultati, ki jih podajo modeli, so odvisni od vhodnih podatkov, zato je težko primerjati različne pristope, v kolikor ti ne temeljijo na enakih vhodnih spremenljivkah. Dodatno težavo predstavljajo mere za vrednotenje modelov, ki ne temeljijo na enakih podatkovnih setih. V tem primeru je priporočljivo uporabiti relativne mere (vom Scheidt in drugi, 2020). Weron (2014) dodaja, da primerjava zanesljivosti modelov ni smiselna, v kolikor vhodni podatki ne zajemajo enakega časovnega obdobja v preteklost ne glede na to, da je napoved narejena za enak trg in obdobje. Uporaba algoritma je odvisna tudi od programskega paketa in od začetnih pogojev v primeru nelinearnih modelov ali modelov z več parametri. Ponovljivost rezultatov je tako lahko nemogoča tudi ob uporabi popolnoma enake strukture modela.

## **5 NAPOVED GIBANJA CEN ELEKTRIČNE ENERGIJE V SLOVENIJI**

Napovedovanje cen električne energije je z liberalizacijo in večjo stopnjo privzemanja električne energije iz obnovljivih virov, postalo kompleksnejše in zahteva združuje znanja s področja elektro inženirstva, statistike, informatike in financ ter s tem omogoča napovedovanje veleprodajnih cen za različna časovna obdobja. Prvi modeli za napovedovanje cen električne energije so bili narejeni v 90. letih 20. stoletja, večinoma s

pomočjo linearne regresije, ki temelji na predpostavki, da obstaja linearna povezava med napovedno spremenljivko in vhodnimi podatki. Prvi modeli so vključevali podatke o preteklih cenah, eksogene spremenljivke in sezonsko komponento. Zadnja je bila običajno slamnata spremenljivka, ki je preučevala vpliv določenega dneva v tednu na ceno. Eksogena spremenljivka se je običajno nanašala na obseg povpraševanja. Strukture napovednih modelov so postale bolj kompleksne z izboljševanjem kapacitet računalnikov in večjo stopnjo gibanja cen električne energije (Jędrzejewski, in drugi, 2022).

Cene električne energije na evropskem trgu odražajo visoko stopnjo nihanja, ki je posledica različnih omejitev, ki jih ima posamezen vir iz katerega je proizvedena električna energija (obseg proizvodnje, odvisnost od vremenskih pogojev, itd.) in zaradi omejenih možnosti shranjevanja. Zmožnost napovedovanja gibanj cen električne energije je postaja pomembno zaradi težnje po energetske tranziciji (Tschora in drugi, 2022).

Podjetja, ki sodelujejo v trgovanju na borzi morajo oddati ponudbe in povpraševanja, pri čemer podjetje, ki najbolj točno napove ceno električne energije, lahko prilagodi svojo ponudbo. Na ta način lahko podjetja z natančnim napovedovanjem oddajo učinkovite ponudbe in hkrati znižajo tveganja, iz česar sledijo boljši poslovni rezultati. Podjetja se običajno poslužujejo različnih načinov trgovanja, kar zahteva tudi napovedovanje cen za različna časovna obdobja ter uporabo različnih napovednih tehnik (Amjady in Hemmati, 2006).

## 5.1 Opis metodologije

Izbor spremenljivk, ki so bile uporabljene v posameznem napovednem modelu, je bil narejen na podlagi ugotovitev v poglavju 3.2. Kot izpostavita Singhal in Swarup (2011), je za nihanje cen električne energije značilna volatilitnost, zaradi česar so napovedni modeli, ki temeljijo zgolj na podatkih o preteklih cenah in povpraševanju, lahko nenatančni. Weron (2014) pri napovedovanju cen za dan vnaprej pripisuje pomembno vlogo osnovnim dejavnikom, saj pretekli podatki o vremenu, povpraševanju, proizvodnji električne energije in ceni primarnih energentov lahko izboljšajo stabilnost modela.

Podatki o ceni električne energije za slovenski trg so objavljeni na spletnem mestu borze South Pool, ki dnevno objavlja urni indeks električne energije za slovenski borzni trg električne energije. Urni indeks je enak marginalni ceni električne energije, ki se trguje za dan vnaprej (BSP Energetska borza d. o. o., brez datuma a).

Podatki o povpraševanju po električni energiji in proizvodnji električne energije glede na primarni vir so na voljo na spletnem mestu Evropskega združenja sistemskih operaterjev elektroenergetskega omrežja (v nadaljevanju ENTSO-E). Podatek o proizvodnji električne energije je izračunan kot povprečje vsega razpoložljivega neto obsega proizvodnje na

določenem trgu za posamezno časovno enoto. V primeru, da podatki niso na voljo, ali v primeru manjših proizvodnih enot brez merilnih naprav za zbiranje podatkov v realnem času je obseg neto proizvodnje ocenjen. Povpraševanje se izračunava kot vsota vse proizvedene električne energije, ki je oddana preko prenosnega ali distribucijskega omrežja. Vsoti je prišteta še vrednost uvoza in odšteta vrednost izvoza elektrike na sosednje trge ter vrednost energije, ki se shrani (ENTSO-E, brez datuma a).

Na kratkoročno napovedovanje cen električne energije najbolj vpliva obseg povpraševanja, ki je med drugim podvržen meteorološkemu pogojem (Mandal in drugi, 2005). Sgarlato in Ziel (2022) izpostavita, da meteorološki podatki izboljšajo natančnost modela pri napovedovanju cen električne energije za dva do štiri dni naprej, medtem ko bi pri napovedih za dan vnaprej lahko dobili manj zanesljive rezultate.

Podatke o povprečni dnevni temperaturi, izmerjeni na glavnih meteoroloških postajah, hrani Agencija Republike Slovenije za okolje (v nadaljevanju ARSO). Na podlagi podatkov trinajstih glavnih merilnih postaj je bila izračunana povprečna dnevna temperatura za Slovenijo.

V učni množici so bili uporabljeni podatki za obdobje od 1. 1. 2017 do 31. 12. 2018 (skupno 730 dni). Podatkovni set vključuje štiriindvajset enot za vsak dan (vsako uro ena enota), kar pomeni, da ima podatkovni set skupaj 17.520 enot. Skupno z 18 spremenljivkami imamo na voljo 315.360 vrednosti. Z enakimi spremenljivkami smo model ovrednotili na podatkih za obdobje od 1. 1. 2019 do 31. 1. 2019. Podatkovni set obsega 17 številskih spremenljivk in eno nominalno, pri čemer je 13 spremenljivk diskretnih in pet zveznih.

Začetna obdelava podatkov je bila opravljena v programu MS Excel, kjer so bili združeni podatki iz različnih virov. Hkrati je bilo podatke treba prilagoditi v obliko, ki ustreza programu RapidMiner. Pri analizi kakovosti podatkov je bilo ugotovljeno, da je podatkovni set pri devetih spremenljivkah vključeval skupno 242 manjkajočih vrednosti, ki so bile nadomeščene s povprečnimi vrednostmi vsake spremenljivke znotraj posameznega leta.

Z vidika preučevanja vpliva vikendov in praznikov na ceno je bila v RapidMinerju ustvarjena še umetna spremenljivka, kjer smo sobotam, nedeljam in praznikom dodelili vrednost 1, medtem ko imajo ostali dnevi v tednu vrednost 0.

Napovedni modeli so bili zgrajeni v programu RapidMiner Studio, verzije 10.1. Gre za orodje, ki preko grafičnega uporabniškega vmesnika omogoča pripravo podatkov in izgradnjo napovednih modelov. Program je bil izbran zaradi enostavne uporabe in izkušenj pri delu s tem programom.

Podrobnejši pregled vhodnih spremenljivk je predstavljen v tabeli 1.

Tabela 1: Metapodatki o vhodnih spremenljivkah

Ime vhodne spremenljivke	Merska enota	Opis spremenljivke	Vir podatka
ATP	EUR/MWh	Marginalna cena na urni avkciji za slovenski borzni trg	SouthPool
ATP_Base	EUR/MWh	Povprečna dnevna cena za posle, sklenjene v urah na slovenskem borznem trgu	SouthPool
ATV	MWh	Obseg trgovanja znotraj posamezne ure na slovenskem borznem trgu	SouthPool
ATV_Base	MWh	Povprečen dnevni obseg trgovanja na slovenskem borznem trgu	SouthPool
Biomass	MWh	Obseg proizvodnje električne energije iz biomase	ENTSO-E
Fossil.Brown.coal/Lignite	MWh	Obseg proizvodnje električne energije iz rjavega premoga (lignita)	ENTSO-E
Fossil.Gas	MWh	Obseg proizvodnje električne energije iz plina	ENTSO-E
Fossil.Oil	MWh	Obseg proizvodnje električne energije iz nafte	ENTSO-E
Hydro.Pumped.Storage	MWh	Obseg proizvodnje električne energije iz črpalnih hidroelektrarn	ENTSO-E
Hydro.Run-of-river.and.poundage	MWh	Obseg proizvodnje električne energije iz pretočno akumulacijskih hidroelektrarn	ENTSO-E
Nuclear	MWh	Obseg proizvodnje električne energije iz nuklearne energije	ENTSO-E
Solar	MWh	Obseg proizvodnje električne energije iz sončne energije	ENTSO-E
Waste	MWh	Obseg proizvodnje električne energije iz odpadkov	ENTSO-E
Wind.Onshore	MWh	Obseg proizvodnje električne energije iz vetrne energije	ENTSO-E
Temperature	°C	Povprečna dnevna temperatura ozračja v Sloveniji	ARSO
Povpraševanje	MWh	Obseg povpraševanja znotraj ure	ENTSO-E
Dan v tednu	Število	Vrednosti od 1 (ponedeljek) do 7 (nedelje in prazniki oziroma dela prosti dnevi)	

Vir: lastno delo na podlagi ARSO (brez datuma); ENTSO-E (brez datuma b); ENTSO-E (brez datuma c); ENTSO-E (brez datuma č); BSP Energetska borza d. o. o. (brez datuma c).

Metode za izgradnjo napovednih modelov so bile izbrane na podlagi pregledane literature. Weron (2014) izpostavi tudi, da najboljše rezultate pri napovedovanju cen za dan vnaprej podajo statistične metode in metode strojnega učenja, ki so podrobneje opredeljene že v prejšnjem poglavju. Lago in drugi (2018a) med metodami strojnega učenja za napovedovanje cen električne energije posebej izpostavijo SVM in metode z osnovo v odločitvenih drevesih.

Za izgradnjo napovednega modela bomo uporabili algoritem XGBoost in SVM. Trend gibanja cen bomo napovedali z metodama ARIMA in Holt-Winters, ki sta posebej namenjeni delu s časovnimi vrstami.

Chen in Guestrin (2016) opisujeta XGBoost kot novejšo metodo gradientnega spodbujanja, katerega osnovni klasifikator je odločitveno drevo. Gre za algoritem nadzorovanega učenja, ki temelji na spodbujanju, kar pomeni, da združi vse šibke modele z namenom izgradnje močnega modela s pomočjo dodatnega učenja. Algoritem se izogne preveliki stopnji prilagajanja modela in optimizira računalniške vire s poenostavitvijo funkcij, ki dovoljujejo kombinacijo napovednih in regularizacijskih členov, hkrati pa ohranja optimalno hitrost izračuna. V fazi učenja se vzporedno samodejno izvajajo izračuni funkcij. Proces učenja modela poteka tako, da je prvi model povsem prilagojen vhodnim podatkom, drugi model pa se prilagodi ostankom šibkega modela. Proces prilagajanja se ponavlja toliko časa, dokler niso izpolnjeni končni kriteriji. Napovedni model temelji na seštevku napovedi posamičnega učnega modela (Fan in drugi, 2018). Zaradi takšnega pristopa uvrščamo XGBoost med ansambelske modele (Jabeur in drugi, 2021). Ciljna funkcija algoritma XGBoost je minimizacija funkcije izgube, ki je razlika med predvideno in dejansko vrednostjo. Regularizacijski člen se uporablja za uravnavanje kompleksnosti modela (Wu in drugi, 2022). Zaradi svoje zasnove XGBoost običajno daje dobre rezultate na strukturiranih podatkih, ampak je pogosto manj prilagodljiv pri uporabi na časovnih vrstah. V tem primeru pristopimo z ustvarjanjem več oken, kjer časovne podatke spremenimo v časovna okna in model učimo na vsakem oknu posebej ter tako zagotovimo večjo napovedovalno moč modela (Zhao in drugi, 2022).

Za izgradnjo napovednega modela je bila uporabljena še metoda SVM. Gre za metodo nadzorovanega učenja, ki se uporablja za prepoznavanje vzorcev, analizo časovnih vrst in razvrščanje (Vani, 2021). SVM ocenjuje regresijo na podlagi serije jedrnih funkcij, ki lahko implicitno pretvorijo prvotne nizko-dimenzionalne vhodne podatke v visoko-dimenzionalni prostor spremenljivk (Fan in drugi, 2018). SVM je učljivi algoritem s klasifikacijsko metodo v dveh korakih. Prvi korak je opredelitev vseh podatkov v prostor  $n$ -dimenzij seta za učenje, kjer je  $n$  število spremenljivk, njihove vrednosti pa so vrednosti koordinat. Drugi korak je identifikacija hiperravnine, ki razlikuje med različnimi razredi. Klasifikacija je izvedena z ustvarjanjem prave hiperravnine med primeri različnih razredov (Altan in Karasu, 2019). Število spremenljivk ne vpliva na kompleksnost modela, hkrati pa ima dobro sposobnost posploševanja. Slabost metode je nižja hitrost izgradnje modela in odvisnost učinkovitosti od izbire parametrov (Caruana in Niculescu-Mizil, 2006).

Holt-Wintersova metoda uporablja trikratno eksponentno glajenje za povprečno vrednost spremenljivke, trend in sezonskost. Metodo definirajo trije parametri – alfa, beta in gama, ki lahko zasedejo vrednosti od 0, 0 do 1,0. Pri tem določa alfa koeficient stopnje glajenja, beta koeficient glajenja trenda in gama določa koeficient stopnje glajenja sezonskosti. Vrsto Holt-Wintersove metode ločimo glede na sezonsko komponento (RapidMiner Documentation,

brez datuma a). Pri aditivnem modelu se predvideva, da so sezonski učinki konstantni. Multiplikativni model pa predvideva, da je sezonski učinek odvisen od stopnje trenda (Chatfield, 1978).

ARIMA je stohastični model, ki temelji na treh fazah: identifikacija modela, ocena parametrov in diagnostično testiranje (Ho in drugi, 2002). Model je sestavljen iz reda treh parametrov –  $p$ ,  $d$  in  $q$ . Pri tem  $p$  določa število avtoregresivnih pogojev modela. Avtoregresivni pogoji določajo, katere pretekle vrednosti bodo uporabljene za napoved. Parameter  $d$  določa število diferenciacij. Diferenciranje se uporablja, ko je prisoten trend in pomaga odstraniti njegov učinek. Parameter  $q$  določa število drsečih povprečij v modelu in določa, kako odkloni povprečij predhodnih vrednosti vplivajo na napovedne vrednosti (Jakaša in drugi, 2011). Model ARIMA je integrirana oblika avtoregresijskega modela drsečih povprečij (angl. autoregressive moving average, v nadaljevanju ARMA), ki opisuje časovne vrste kot tehtano vsoto zamaknjenih vrednosti in ostankov. Ostanki so v tem primeru posledica normalne porazdelitve napak. Vrednosti modela ARMA so integrirane, kar pomeni, da so vrednosti časovnih vrst, ki jih opisuje ARMA, enake diferenciranim (RapidMiner Documentation, brez datuma b). ARIMA uvrščamo med univariatne modele, kar pomeni, da napoved temelji na eni časovni vrsti (Kirchgässner in drugi, 2007).

V tem poglavju je zajeto tudi vrednotenje modelov, za kar uporabimo naslednje vrste statističnih napak (Chicco in drugi, 2021):

- **Absolutna napaka (angl. Mean absolute error, v nadaljevanju MAE)** je merilo, s katerim ocenjujemo točnost (numeričnih) modelov. Postopek izračuna se izvede tako, da posameznim napovedim, narejenim na testnih podatkih, najprej odštejemo pripadajočo dejansko vrednost odzivne spremenljivke na testnih podatkih. Vzamemo absolutne vrednosti, torej negativne pomnožimo z  $-1$ . Nato rezultate seštejemo in dobljeno vrednost delimo s številom napovedi. Dobljena vrednost nam v enotah odzivne spremenljivke pove, za koliko se v povprečju naše napovedi motijo.
- **Relativna napaka (angl. Mean absolute percentage error, v nadaljevanju MAPE)** nam pove, kakšen odstotek povprečja dejanskih vrednosti predstavlja srednja absolutna napaka. Izračunana je kot količnik absolutne napake in povprečja dejanskih vrednosti.
- Za boljšo predstavo o točnosti modela uporabljamo še **koren srednje kvadratne napake (angl. Root mean squared error, v nadaljevanju RMSE)**. Gre za podobno mero kot absolutna napaka in je izračunana s tem, da posameznim napovedim, narejenim na testnih podatkih, najprej odštejemo pripadajočo dejansko vrednost odzivne spremenljivke v testnih podatkih. Nato posamezne dobljene vrednosti kvadriramo in rezultate seštejemo ter dobljeno številko delimo s številom napovedi. Na koncu rezultat še korenimo. Glede na to, da smo dobljene razlike pred seštevanjem kvadrirali, to pomeni, da za razliko od absolutne napake posamezni ostanki tukaj  $k$  vrednosti celotne napake prispevajo proporcionalno glede na kvadrirano napako in ne neposredno proporcionalno, kot je to pri absolutni napaki.



Večja odstopanja bodo imela tu zato večji vpliv. Po končnem korenjenju zato dobimo drugačno (običajno večjo) vrednost kot pri absolutni napaki – če je ta vrednost veliko večja, pomeni, da imamo v napovedih znatno število večjih odstopanj.

## 5.2 Podatki o preteklem gibanju cen električne energije v Sloveniji

Tabela 2 prikazuje opisno statistiko za ceno električne energije na slovenskem borznem trgu med leti 1. 1. 2017 in 31. 12. 2018. Za obravnavano obdobje sta bili najnižja in najvišja cena za MWh na slovenski borzi za električno energijo doseženi leta 2017, saj je najnižja cena znašala –42,93 EUR, najvišja pa 199 EUR. Na podlagi izračunane variance lahko ugotovimo, da so bila nihanja cen večja v letu 2017.

*Tabela 2: Opisna statistika*

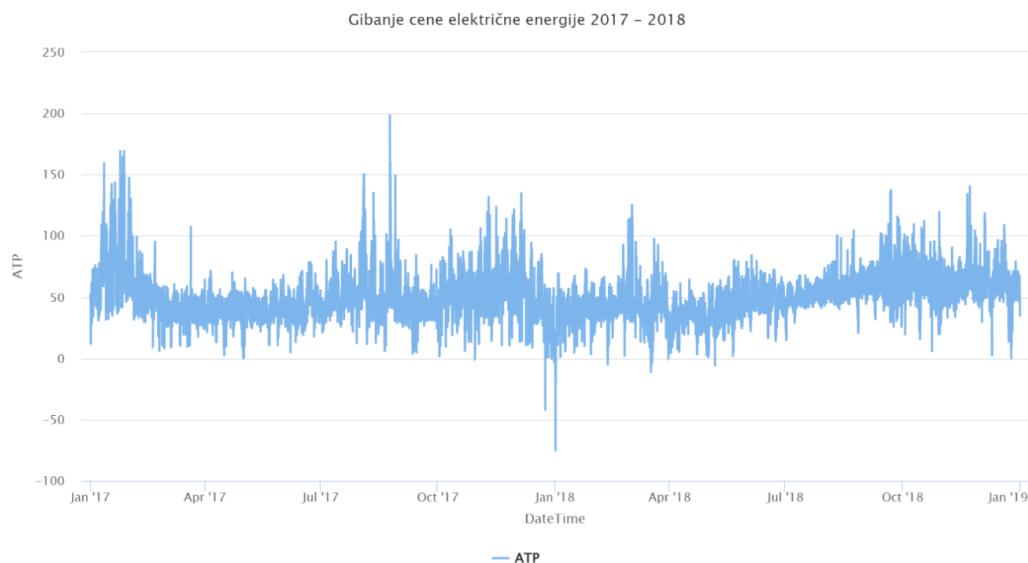
	<b>Min.</b>	<b>Max.</b>	<b>Povprečje EUR/MWh</b>	<b>Standardni odklon</b>	<b>Varianca</b>
ATP2017/2018	–42,93	199	50,34	20,26	410,47
ATP2018	–76,01	141,25	49,95	18,54	343,73
ATP2017	–42,93	199	49,52	21,64	468,29

*Vir: lastno delo.*

Na rast cen električne energije v letih 2017 in 2018 na borzi South Pool, v primerjavi s prejšnjimi leti so imeli največji vpliv slaba hidrologija v Evropi, ter posledično manjši obseg proizvodnje električne energije v hidroelektrarnah, tehnične težave termo elektrarne Šoštanj v letu 2017 in rast cen emisijskih kuponov (Agencija Republike Slovenije za energijo, 2017 in Agencija Republike Slovenije za energijo, 2018).

Slika 1 prikazuje gibanje cen električne energije med leti 2017 in 2018. Vidimo, da so nihanja med dnevi velika, trend pa bi težko opisali, kljub temu, da je v določenih obdobjih (v začetku julija 2018) viden vzorec gibanja. Zato bomo uporabili statistične metode in metode strojnega učenja.

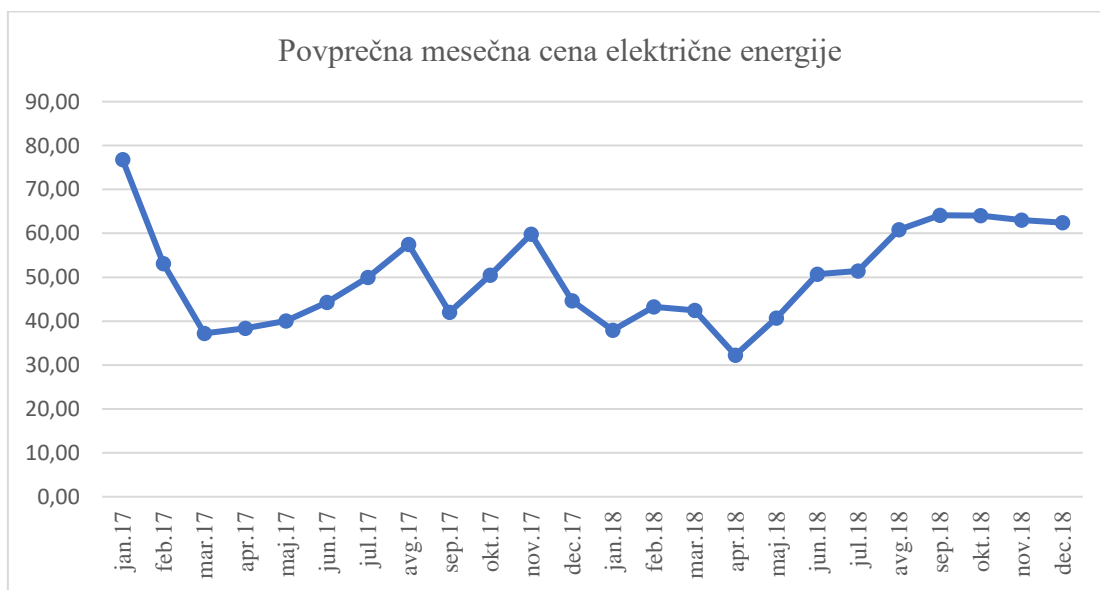
Slika 1: Grafični prikaz gibanja cen električne energije na borzi South Pool v letih 2017 in 2018



Vir: lastno delo.

Povprečna cena električne energije je bila višja v letu 2018 (51,16 EUR) v primerjavi z letom 2017 (48,74 EUR). Z vidika sezonskosti lahko iz slike 2 razberemo, da je bila povprečna cena za MWh nižja med marcem in junijem, pri čemer je bila v letu 2017 najnižja cena dosežena marca (37,2 EUR/MWh), v letu 2018 pa v aprilu (32,3 EUR/MWh). Rast cen se, kot je vidno na sliki 2, zabeleži ob koncu poletja (avgust, 2018) oziroma začetku jeseni (oktober, 2017). Najvišja povprečna mesečna cena je bila v letu 2017 dosežena marca (76,8 EUR/MWh), v letu 2018 pa januarja (64,2 EUR/MWh).

Slika 2: Povprečna mesečna cena (EUR/MWh) električne energije na slovenski borzi South pool med leti 2017 in 2018




Vir: lastno delo.

### 5.3 Izgradnja modela za napovedovanje gibanja cen električne energije

Po uvozu podatkov v RapidMiner je bilo ugotovljeno, da stolpec z datumi ne vsebuje unikatnih vrednosti. Zato sem z operatorjem »Odstrani duplikate« eno vrstico odstranila. S pomočjo operatorja »Ustvari atribute« sem naredila umetno spremenljivko, s katero sem delovnim dnevom dodelila vrednost 0 in vrednost 1 dela prostim dnevom. Z operatorjem »Nominalne vrednosti v datume« sem preoblikovala datum iz nominalne oblike v datum. Po uvozu podatkov v RapidMiner podatki niso bili razvrščeni v pravilnem sosledju, zato sem z operatorjem »Razvrsti« dodelila padajoč vrstni red. Pridobila sem urejen podatkovni set, ki je bil shranjen z operatorjem »Shrani«. Slika 3 prikazuje proces obdelave podatkov v programu RapidMiner in izbrane attribute.

Slika 3: Predprocesiranje podatkov v programu RapidMiner

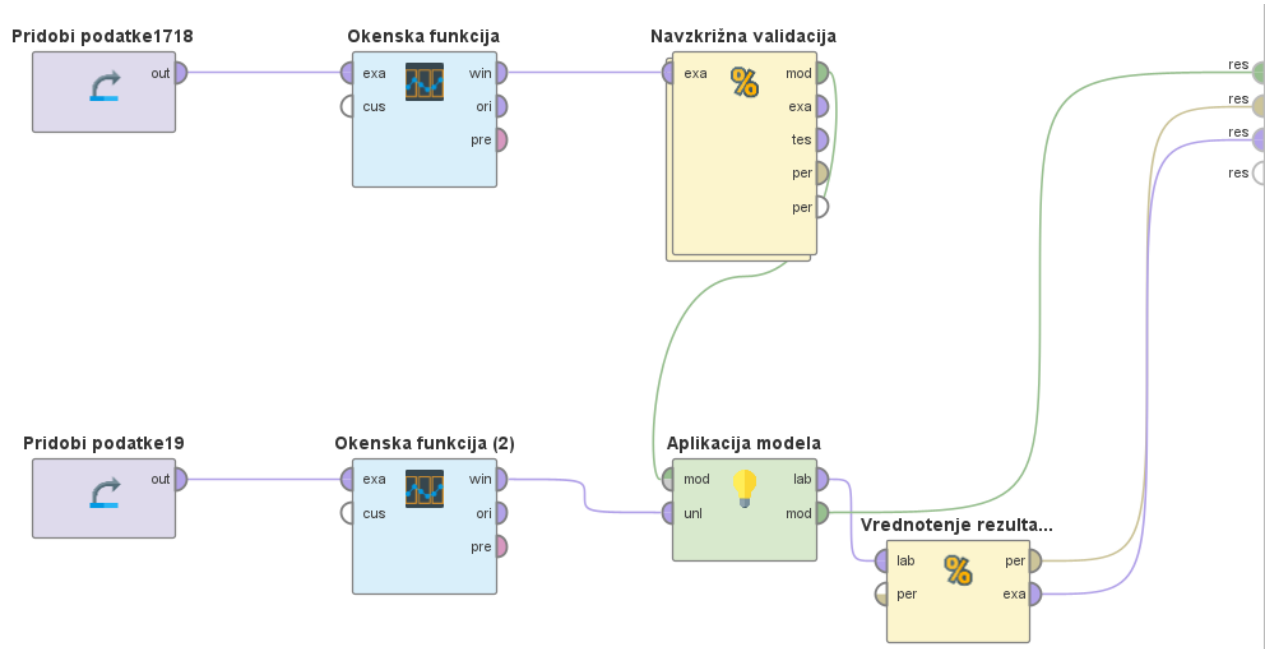


Vir: lastno delo.

S prvim napovednim modelom sem želela napovedati ceno električne energije glede na vrednosti napovednih spremenljivk. Pri izgradnji napovednih modelov je bil vsakič uporabljen enak podatkovni set z enakimi spremenljivkami. Za izgradnjo prvega modela je bil na vhodnih podatkih najprej uporabljen operator »Ogenska funkcija«, ki časovne vrste preoblikuje v okna za učenje z izbranim modelom. Na ta način lahko časovne vrste preoblikujemo v podatkovni set za nadzorovano učenje, kjer glede na predhodne vrednosti lahko predvidevamo prihodnje. Pridobimo večdimenzionalni podatkovni set za strojno učenje, na katerem se model lahko uči (Rapidminer, brez datuma). Z operatorjem sem datumu določila vlogo indikatorja. Širina okna znaša 24, kar pomeni, da smo za vsako spremenljivko ustvarili 24 oken. Ustvarjene se bile nove spremenljivke oken, kjer so vrednosti zamaknjene za  $n$ , pri čemer je  $n$  določeno število ur. Z namenom napovedovanja cene za en teden vnaprej sem ustvarila proces s 168 okni. Horizont napovedovanja sem nastavila tako, da dobim napoved za vsak dan ob isti uri. Vlogo odzivne spremenljivke sem dodelila ceni električne energije. S pomočjo navzkrižne validacije, ki je prikazana na sliki 5, je bil izbrani algoritem naučen na našem podatkovnem setu. Slednje pomeni, da je algoritem nameščen tako na učne kot tudi na testne podatke. V tem procesu sem uporabila XGboost in SVM. Naknadno sem ugotovila, da podatki o temperaturi ne prispevajo k boljšim rezultatom, zato je bila ta spremenljivka odstranjena iz modela.


Napovedni model smo z enakimi operatorji preverili na podatkih iz leta 2019. Proces izgradnje modela v programu RapidMiner je prikazan na sliki 4.

Slika 4: Proces izgradnje modela v programu RapidMiner



Vir: lastno delo.


Slika 5: Podproces znotraj navzkrižne validacije



Vir: lastno delo.

Na sliki 6 lahko vidimo dejansko gibanje cen (zeleno barvo) ter napoved (modra barva) z metodo XGBoost v obdobju od januarja 2019 do januarja 2020. Slike 6 lahko sklepamo, da se napovedi dokaj dobro prilegajo dejanskim vrednostim (z nekaterimi odstopi, kot je na primer v januarju 2019), metoda predvidi tudi skoke cen.

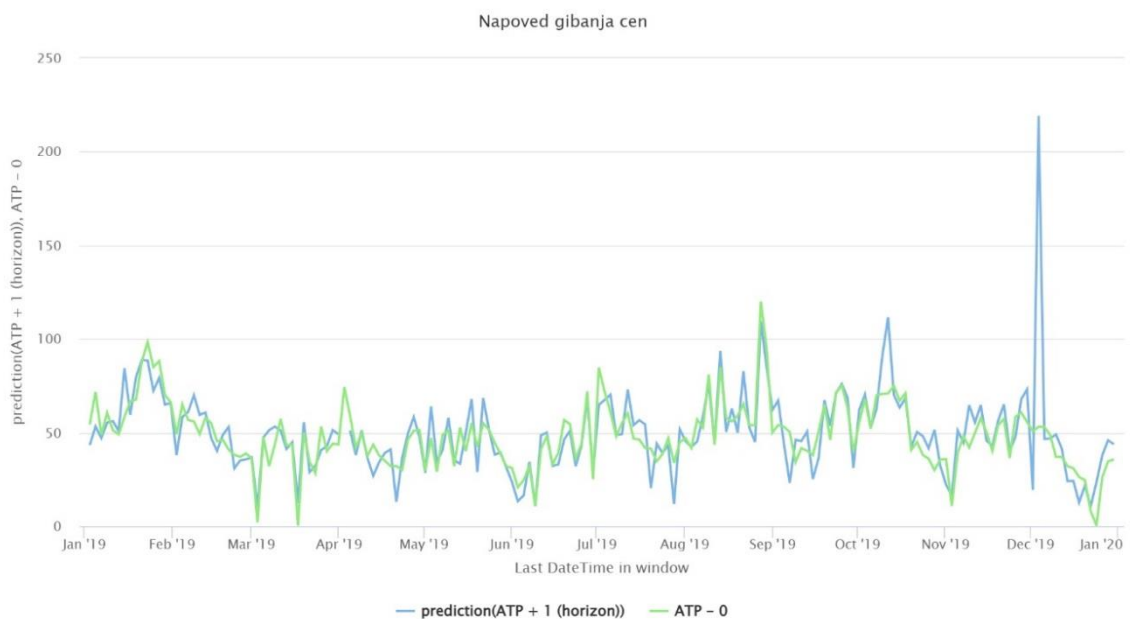
*Slika 6: Napoved gibanja cene za dan vnaprej z metodo XGBoost*



*Vir: lastno delo.*

Na sliki 7 prav tako vidimo napovedane in dejanske vrednosti ATP v istem obdobju. Že na začetku opazimo, da se vrednosti bolj razlikujejo – skoki napovedanih vrednosti so večji, prav tako pa se slabše prilegajo skokom dejanskih vrednosti.

*Slika 7: Napoved gibanja cene za dan vnaprej z metodo SVM*



*Vir: lastno delo.*

S primerjavo na podlagi slik 6 in 7 lahko ugotovimo, da gibanje cen učinkoviteje prepozna XGBoost, vendar slabše prepozna znatnejša nihanja cene, ki jih podceni oziroma preceni. Na drugi strani napoved s SVM poda manj natančne rezultate tudi ob zmernem nihanju cen in napove skoke cen, ki v dejanskih podatkih niso prisotni. Podrobnejše mere prileganja ter njihova primerjava je navedena v tabeli 3.

#### 5.4 Aplikacija modela na podatke

Tehtana povprečna napaka (RMSE) med napovedjo in dejanskimi vrednostmi pri 24-urnem oknu in uporabi algoritma XGB znaša 8,24, medtem ko pri uporabi SVM znaša 9,33. V kolikor preverimo povprečno relativno napako, lahko rečemo, da so v povprečju naše napovedi pri uporabi XGB za 16,95 % odmaknjene od ciljne vrednosti, medtem ko so pri SVM za 25,77 % odmaknjene od ciljne vrednosti. Povprečna napaka med predvidenimi in dejanskimi vrednostmi pri 24-urnem oknu z algoritmom XGB znaša 5,65, medtem ko pri SVM znaša 6,39. Pri tedenskem oknu znaša pri XGB 5,86, medtem ko pri SVM znaša 9,51.

Pri uporabi tedenskega okna znaša tehtana povprečna napaka (RMSE) med napovedjo in dejanskimi vrednostmi 7,67 pri uporabi XGB in 12,33 pri uporabi SVM. V povprečju so naše napovedi pri tedenskem oknu ob uporabi XGB za 12,14 % odmaknjene od ciljne vrednosti, medtem ko so pri SVM za 21,25 % odmaknjene od ciljne vrednosti.

V vseh primerih je RMSE večji od MAE, kar pomeni, da odstopanja med dejanskimi vrednostmi in podatki niso povsem konsistentna. Glede na to, da z algoritmom XGBoost v obeh primerih dosežemo manjši RMSE, lahko rečemo, da se modela bolje prilagajata podatkom. Zaključimo lahko, da na podlagi danih statističnih napak XGBoost poda zanesljivejše napovedi gibanja cen.

Zanesljivost napovednega modela lahko ugotovimo tudi s preverjanjem pretiranega prileganja (angl. overfitting). Za obravnavana modela lahko rečemo, da pretirano prileganje ni prisotno, saj je model na testni množici podal boljše rezultate kot na učni. Hkrati sta uporabljena modela dovolj splošna, zato je možnost za pretirano prileganje majhna.

*Tabela 3: Rezultati*

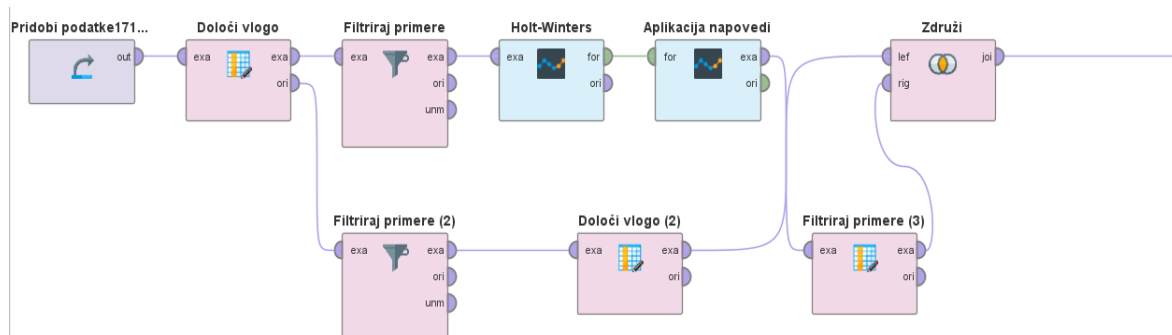
	<b>RMSE</b>	<b>MAPE</b>	<b>MAE</b>
XGB (24-urno okno)	8,24	16,95 %	5,65
SVM (24-urno okno)	9,33	25,77 %	6,39
XGB (tedensko okno)	7,67	12,14 %	5,86
SVM (tedensko okno)	12,33	21,25 %	9,51

*Vir: lastno delo.*

## 5.5 Napoved gibanja cen električne energije v Sloveniji

Trend smo napovedovali z metodama Holt-Winters in ARIMA, ki sta posebej prilagojeni za delo s časovnimi vrstami. Uporabili smo podatkovni set z enakimi spremenljivkami, vendar je bila za napoved uporabljena povprečna dnevna cena električne energije na borzi South Pool. S procesom je bila napovedana cena za en mesec vnaprej. Z operatorjem »Določi vlogo« je bila povprečna dnevna cena označena kot odzivna spremenljivka, datum pa kot indikator. Podatke smo filtrirali tako, da množica, na kateri bomo gradili model, vključuje podatke do 1. 12. 2019. Pri metodi Holt-Winters smo prilagodili parametre alfa, beta in gama, pri čemer ima alfa vrednost 0,7, beta 0,1 in gama 0,7. Visoka vrednost alfe in game pomenita, da se nivo in sezona močno spreminjata (Hyndman in Athanasopoulos, 2018). Kot dolžino ene sezone smo določili 30 dni, saj delamo napoved za enako število dni. Z operatorjem »Aplikacija napovedi« določimo še število dni, za katere je bila narejena napoved. Za izgradnjo modela z metodo ARIMA je bil uporabljen enak proces. Prilagojeni so bili parametri  $p$ ,  $d$  in  $q$ , pri čemer ima  $p$  vrednost 30,  $d$  vrednost 0 in  $q$  vrednost 1. Za potrebe vizualizacije testnih podatkov in napovedi smo uporabili operator »Združi« (slika 8).

Slika 8: Proces v programu RapidMiner




Vir: lastno delo.

Sliki 9 in 10 prikazujeta gibanje povprečne dnevne cene za december 2019. Napovedni model pri obeh metodah gleda podatke za november, saj smo dodelili zamik za 30 dni. V tem obdobju je gibanje cen dokaj konsistentno, okoli 45 EUR/MWh, cena se začne spuščati v sredini decembra.

Na sliki 9 vidimo, da metoda Holt-Winters prepozna nihanje cene, ampak sprva napove nižjo ceno kot je dejanska. V drugi polovici decembra se nato napovedi bolj približajo dejanskim vrednostim, čeprav še vedno z nekaterimi odstopanji ter brez napovedi skoka cene okrog 28. decembra.

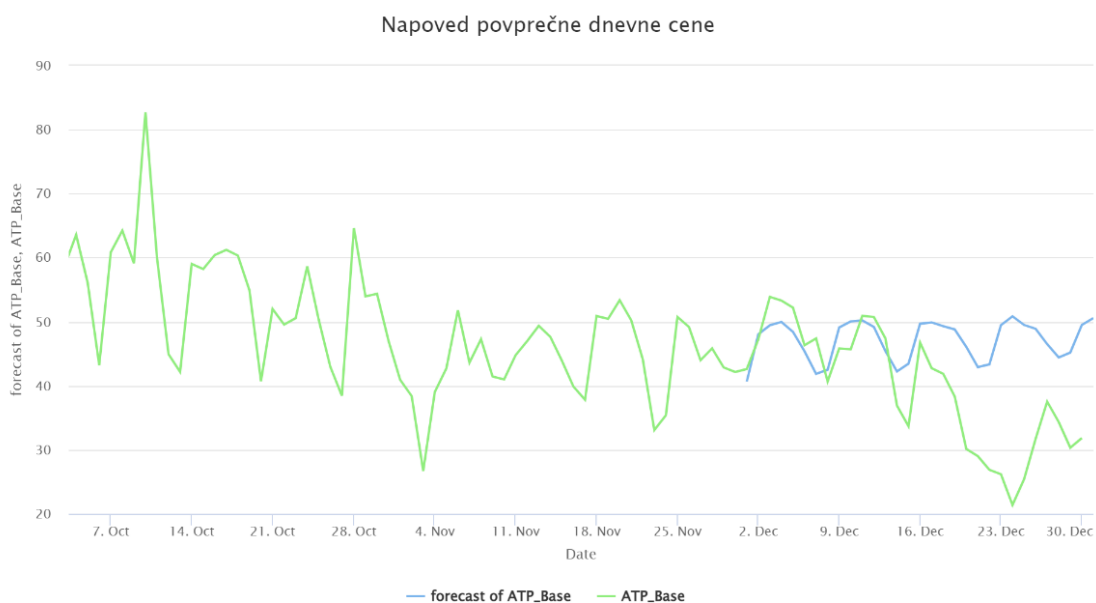
Slika 9: Napoved povprečne dnevne cene z metodo Holt-Winters



Vir: lastno delo.

Slika 10 prikazuje napoved trenda z metodo ARIMA, kjer lahko vidimo, da so dolgoročne napovedi gibanja cen nezanesljive. Namreč v prvi tretjini decembra je napoved razmeroma dobra, kasneje pa se ta začne ponavljati in nadaljuje do konca napovednega obdobja – čeprav je bil trend dejanskih cen v drugi polovici decembra usmerjen izrazito padajoče (s skokom okrog 28. decembra).

Slika 10: Napoved povprečne dnevne cene z metodo ARIMA



Vir: lastno delo.



Metoda ARIMA nadaljuje trend gibanja cene v novembru, zaradi česar je vzorec napovedi konsistenten, medtem ko Holt-Winters bolje prepozna vzorce gibanja cene in s tem lahko poda tudi bolj zanesljivo napoved.

Na podlagi rezultatov, ki jih podata obe metodi, lahko rečemo, da se podatkom bolje prilaga napoved z metodo Holt-Winters, ki v večini primerov prepozna nihanja cene, ampak napove nižjo ceno, kot je dejanska. Z metodo ARIMA ne dobimo podrobnih informacij o gibanju cene, saj slabo zaznava nihanja.

## 6 DISKUSIJA

### 6.1 Ključne ugotovitve

Po liberalizaciji trga električne energije so podjetja na veleprodajnem trgu začela v večjem obsegu trgovati bilateralno in na borzah. Hkrati so se cene začele oblikovati na trgu, kar je pomenilo konec stabilnosti cen. Razlogi za nihanje cen so različni. Escribano in drugi (2011) med poglavitne razloge uvrščajo nezmožnost učinkovitega shranjevanja električne energije in potrebo po stalni uravnoveženosti proizvodnje in potrošnje. Povpraševanje po elektriki je neelastično, saj velja za nujno surovino. Podjetja stremijo k optimizaciji prihodkov, pri čemer si pomagajo z napovedovanjem obsega proizvodnje in povpraševanja trem gibanja cen in na ta način oblikujejo načrte za trgovanje na borzi. Amjady in Hemmati (2006) izpostavita, da podjetja, ki trgujejo z električno energijo, lahko na podlagi zanesljivih napovedi sprejemajo informirane odločitve pri oddaji ponudb in s tem zmanjšajo finančna tveganja. V ta namen podjetja potrebujejo raznolike informacije o cenah goriv in zmogljivosti infrastrukture na različnih območjih. Cena se določi na podlagi presečišča ponudbe in povpraševanja, pri čemer je povpraševanje med drugim podvrženo vremenskim nihanjem in sezonskim spremembam (Amjady in Hemmati, 2006). Meteorološki podatki so v napovedih pomembni tudi z vidika pridobivanja električne energije iz obnovljivih virov. Zaradi integracije obnovljivih virov energije v omrežje se zahtevnost napovedovanja cen povečuje (Kardoš in drugi, 2021).

Pri izbiri metode za napovedovanje cen električne energije Abraham in Ledolter (1983) omenita želeno stopnjo natančnosti modela, časovni okvir napovedovanja, višino stroška, ki je sprejemljiva za pripravo napovedi, stopnjo kompleksnosti in razpoložljivost podatkov. Pri napovedovanju dajejo metode časovnih vrst dobre rezultate v primerih, ko je gibanje cen konsistentno. Slednje pomeni, da kot linearni napovedovalci metode časovnih vrst ob visoki variaciji podatkov, ki je značilno za urne cene, dajejo manj zanesljive rezultate kot v primeru tedenskih ali mesečnih podatkov. Posledično so se bolj začele uporabljati metode strojnega učenja, saj te lahko premostijo težave z visoko frekvenco podatkov (vom Scheidt in drugi, 2020). Lago in drugi (2018a) v svojem delu kot zanesljivi metodi izpostavijo SVM in modele, ki temeljijo na odločitvenih drevesih, med drugim tudi XGBoost. Glede na to, da

gre za novejšo metodo, je v napovedovanju cen električne energije manj prisotna. Kljub temu so Xie in drugi (2022) ugotovili, da je prednost obravnavanega algoritma v kratkem času izgradnje modela in majhni kompleksnosti ter manjšem tveganju za pretirano prileganje podatkom. Pri napovedovanju lahko uporabimo še hibridne metode, ki omogočajo preučevanje različnih lastnosti podatkov in zato lahko podajo boljše rezultate. Kljub temu je postopek izgradnje modela preveč zamuden za vsakdanjo uporabo (Lago in drugi, 2018a).

Zhao in drugi (2022) so ugotovili, da XGBoost dobro deluje na strukturiranih podatkih, posledično pa se slabše znajde na časovnih podatkih. V tem primeru uporabimo metodo ustvarjanja več oken, kjer namesto na časovnih podatkih model učimo na vsakem oknu posebej in zagotovimo večjo napovedno moč modela.

Z modelom v magistrskem delu je bila narejena primerjava metode SVM in algoritma XGBoost. Pri napovedovanju cen v odvisnosti od vrednosti ostalih spremenljivk je bilo ugotovljeno, da boljše napovedi tako za dan vnaprej kot tudi za en teden vnaprej poda XGBoost, saj RMSE v tem primeru znaša 8,24 €/MWh oziroma 7,67 €/MWh. Omenjena metoda napove nihanja, vendar ta običajno niso povsem točna, medtem ko metoda SVM poda slabše napovedi tudi, ko so nihanja zanemarljiva, hkrati tudi napove skoke cen, ki se v resnici niso zgodili.

Pretirano prileganje modela na podatke v primeru uporabljenih modelov ni bilo prisotno, saj so bili rezultati na testnih podatkih boljši kot na učnih. Glede na to, da je model precej splošen, je bila verjetnost za pretirano prileganje majhna. V primeru pretiranega prileganja podatkov bi lahko v učno množico dodali podatke za daljše časovno obdobje.

V primeru napovedi trenda sta bili uporabljeni metodi napovedovanja s časovnimi vrstami, pri čemer uporabimo metodo ARIMA in Holt-Winters. Pri primerjavi rezultatov napovedi je bilo ugotovljeno, da Holt-Winters poda boljšo napoved, saj ob manj konsistentnem gibanju cen prepozna trend in posledično poda boljšo napoved. Glede na to, da je bil model učen na podatkih za november, ko je nihanje cen večje, je rezultat modela pričakovan, saj ARIMA slabše deluje na nelinearnih podatkih. Posledično bi bilo smiselno uporabiti metodo GARCH, saj ta meri tudi nihanja cen.

## **6.2 Pomen ugotovitev za podjetja**

Napovedovanje cen električne energije pomaga udeležencem na trgu pri sprejemanju odločitev glede oddaje ponudb, razporeditvi portfelja in načrtovanju investicij. Pri kratkoročnem trgovanju udeleženci uporabijo napovedi cen na dnevnem trgu in kratkoročnem terminskem trgu in prilagodijo ponudbe ter s tem optimizirajo dobiček. Za srednjeročno trgovanje udeleženci uporabljajo napovedi kot referenco za terminsko in bilateralno trgovanje ter si s tem zagotovijo optimalno razporeditev sredstev. Dolgoročna napoved cen služi elektrarnam kot zagotavljanje za povračilo naložb v proizvodnjo, prenos

in distribucijo. Operaterji trga si z napovedovanjem cen pomagajo pri izračunu indeksov in spremljanju trga. Spreminjanje razmer na trgu lahko vodi v večjo nestabilnost cen, pri čemer spremljanje cen igra ključno vlogo za spremljanje vedenja deležnikov in stanja trga (Li in drugi, 2007).

Magistrsko delo zajema predstavitev in primerjavo različnih metod in tehnik napovedovanja, ki so jih avtorji uporabili za napovedovanje cen električne energije na liberaliziranih trgih. Hkrati zajema nabor različnih spremenljivk iz prosto dostopnih virov, ki vplivajo na gibanje cene električne energije in možnosti njihove uporabe v napovednih modelih.

Na podlagi izgrajenih modelov lahko primerjamo algoritma SVM in XGB pri napovedovanju cene na slovenski borzi glede na vrednosti ostalih spremenljivk. Obenem na podlagi povprečne dnevne cene z napovedjo cene za en mesec vnaprej primerjamo dve metodi časovnih vrst.

### **6.3 Omejitve raziskave**

Magistrsko delo ima tudi določene omejitve. Navkljub dejstvu, da se metode strojnega učenja pogosto uporabljajo za napovedovanje cen električne energije, pogosto model težko interpretiramo in pojasnujemo rezultat. Hkrati model pričakuje, da bodo prihodnji dogodki podobni preteklim. Posledično model v primeru izrednih okoliščin, kot jih je povzročila epidemija covid-19, pomanjkanje primarnega energenta (plina) spomladi 2021 oziroma geopolitične razmere v letu 2022, ne daje zanesljivih rezultatov. Ravno iz tega naslova so bili za izdelavo magistrskega dela uporabljeni podatki od leta 2017 do 2019.

Dodatno omejitev lahko izpostavimo pri programu RapidMiner, saj z operatorjem »Apply forecast« lahko le nadaljujemo časovno vrsto iz učne množice, ki smo jo učili. Operator za delovanje potrebuje učno množico, ki je kompatibilna z modelom. Hkrati je model za napovedovanje zelo odvisen od podatkov, zato so že vključeni v napovedni model. Slednje pomeni, da operator ne omogoča učenja na eni učni množici in apliciranja naučenega modela na novega, zato naučenega modela ne moremo uporabiti na drugih podatkih (RapidMiner Documentation, brez datuma c).

Cena elektrike se razlikuje tudi med posameznimi državami, saj imajo te različne stroške, povezane z omrežji ter pridobivanjem električne energije, in drugačno strukturo pridobivanja električne energije glede na vir. Model je bil izgrajen na podatkih, ki veljajo za slovenski trg električne energije, zaradi česar bi ob uporabi podatkov za drug trg dobili drugačne rezultate. Hkrati bi bilo treba vključiti drugačne spremenljivke in prilagoditi model.

Kljub temu, da se meteorološki podatki uporabljajo v modelih za napovedovanje cen električne energije, se v našem primeru spremenljivka o temperaturi zraka ni izkazala za uporabno in je bila naknadno umaknjena iz analize.

Izgradnja modela z metodo SVM je potekala nekoliko več časa, kar bi v praksi lahko pomenilo, da je ob večjem obsegu podatkov manj uporabna. Parametri pri posamezni metodi oziroma algoritmu so bili izbrani na podlagi 'primerov dobrih praks' in preverjanju stopnje zanesljivosti modela glede na spreminjanje vrednosti. Posledično lahko to pomeni, da je napoved pristranska.

Za metode strojnega učenja sicer velja, da v primerjavi z ostalimi metodami dajejo boljše rezultate, ampak je njihova pomanjkljivost v podajanju podrobnejših informacij o izgrajenih modelih. Slednje pomeni, da ne vemo, kakšen je vpliv posamezne spremenljivke na napoved.

#### **6.4 Priložnosti za nadaljnje delo**

Magistrsko delo bi lahko nadgradili v smeri izboljšave napovednega modela. Glede na to, da trenutni model temelji na podatkih za slovenski trg, bi bilo smiselno preučiti možnost izgradnje robustnega modela, ki bi ga lahko uporabili za napovedovanje cen električne energije na drugih trgih. Dodatno bi bilo smiselno primerjati rezultate modela, če bi bil ta izgrajen na podatkih za daljše časovno obdobje. V kolikor bi želeli izgraditi model za napovedovanje za daljše časovno obdobje, bi bilo smiselno v obliki vhodnih spremenljivk vključiti napoved povpraševanja.

Nadalje bi lahko uporabili napovedne modele še z drugimi metodami strojnega učenja in statističnimi metodami ter naredili primerjavo učinkovitosti in uporabnosti s hibridnim modelom, ki bi temeljil na obeh prej omenjenih metodah.

Za modele, zgrajene s strojnim učenjem, je značilno, da nudijo omejene možnosti interpretacije. Zato bi z analizo delne odvisnosti lahko preverili, kako posamezna spremenljivka vpliva na napoved modela. Dodatno bi lahko metode strojnega učenja uporabili za preučevanje odvisnosti cene od ostalih spremenljivk.

Glede na naravo gibanja cen električne energije, ki vključuje visoka nihanja cen, bi bilo v nadaljnje smiselno preučiti možnosti napovedovanja večjih nihanj.

V nadaljnje bi bilo z določanjem različnih vrednosti parametrov smiselno preučiti rezultate napovednih modelov ter preučiti možnost optimizacije in avtomatizacije določanja parametrov.

Z vidika ugotavljanja pomena programske opreme pri izgradnji napovednih modelov in glede na omejitve, ki jih ima RapidMiner, bi lahko za izgradnjo modelov uporabili še programa Python ali R ter primerjali učinkovitost programov in morebitna odstopanja med rezultati.

## 7 SKLEP

Teoretični del magistrskega dela temelji na pregledu znanstvene in strokovne literature s področja energentov. Prvo poglavje zajema pregled evropskega energetskega trga. Z vidika strukture energentov se evropski trgi med seboj precej razlikujejo. Države, ki so bolj odvisne od uvoza fosilnih goriv, so tudi bolj izpostavljene geopolitičnim tveganjem. Na drugi strani so trgi v različni meri naklonjeni prevzemanju obnovljivih virov energije. Podjetja so z energenti začela trgovati sprva z nafto in plinom. Posebnost energetskega trga je elastičnost ponudbe in povpraševanja, zahtevnost dobav, prenosov in shranjevanja. Načini trgovanja z energenti so prilagojeni značilnostim posameznega energenta. Posebej za električno energijo velja, da morata biti ponudba in povpraševanje konstantno usklajena. Podjetja morajo v času hitrih sprememb in visoke stopnje konkurence stremeti k sprejemanju informiranih odločitev. Podjetja na energetskem trgu se spoprijemajo z iskanjem načinov uporabe tehničnih in poslovnih podatkov. Podatkovna analitika med drugim podjetjem pomaga razumeti dogajanje na trgu. Različni načini uporabe podatkovne analitike pomagajo tako podjetjem pri razvoju strategij kot tudi zaščiti pred finančnimi tveganji, na drugi strani pa si države z uporabo podatkovne analitike pomagajo pri prilagajanju zakonodaje.

Večjo prelomnico na evropskem elektroenergetskem trgu predstavlja uvedba liberalizacije, kar je prineslo številne spremembe. Poleg večje stopnje diverzifikacije so bila podjetja zaradi uvedbe konkurence prisiljena v večje investicije in razvoj, hkrati pa se je v večjem obsegu začelo trgovati z električno energijo na borzah in bilateralno. Za trg električne energije velja nekaj posebnosti. Med drugim ta, da je delovanje trga podvrženo fizičnim značilnostim elektrike, saj je ni možno učinkovito shranjevati, zaradi česar morata biti ponudba in povpraševanje stalno usklajena. Udeleženci elektroenergetskega trga se temu lahko prilagodijo z napovedovanjem obsega povpraševanja in ponudbe. Trgovanje z električno energijo poteka na podlagi pričakovanega povpraševanja, zato so produkti diferencirani glede na časovni okvir.

Na slovenskem trgu električne energije deluje borza SouthPool, ki omogoča trgovanje znotraj dneva, za dan vnaprej, na izravnalnem trgu in dolgoročnih avkcijah za fizične produkte. Pretekli podatki o cenah za dan vnaprej so bili uporabljeni kot vhodni podatki za napovedne modele.

Napovedovanje cen električne energije je postalo ključni del odločevalnega mehanizma, saj različni horizonti napovedi pomagajo tako podjetjem, ki trgujejo z električno energijo, kot

tudi proizvajalcem električne energije. Podjetja se za izbiro napovedne metode odločijo na podlagi različnih dejavnikov, med katerimi so zelena stopnja natančnosti modela, časovni okvir napovedovanja, višina stroška, ki je sprejemljiva za pripravo napovedi, stopnja kompleksnosti in razpoložljivost podatkov. Tretje poglavje se pretežno osredotoča na opis statističnih metod in metod strojnega učenja, s katerimi so avtorji že napovedovali cene električne energije. Pri primerjavi omenjenih metod avtorji prednost dajejo metodam strojnega učenja, saj so podatki o gibanju cen električne energije nelinearni, zaradi česar potrebujemo nelinearne modele.

V empiričnem delu je predstavljena metodologija z opisom spremenljivk in postopka obdelave podatkov ter analiza gibanja cen električne energije na slovenski borzi SouthPool. Analiza preteklega gibanja cen je pokazala, da je bila povprečna cena v obravnavanih letih 2017 in 2018 zelo podobna, a so bila večja nihanja prisotna v letu 2017.

Namen magistrskega dela je bil prikazati postopek izgradnje modela strojnega učenja, ki bo na osnovi analize gibanja ekonomskih parametrov in časovnih vrst omogočil napovedovanje cen električne energije v Sloveniji. Proces izgradnje modelov je potekal v programu RapidMiner, kjer smo pred apliciranjem algoritma časovne vrste preoblikovali v okna in s tem pridobili podatkovni set za nadzorovano učenje. Za napoved cene električne energije v odvisnosti od ostalih spremenljivk sta bili uporabljeni metodi XGBoost in SVM, pri čemer je bilo ugotovljeno, da bolj zanesljivo napoved poda XGBoost. Za napoved trenda sta bili na podlagi podatkov o povprečni dnevni ceni uporabljeni metodi časovnih vrst ARIMA in Holt-Winters, ki je tudi podala boljšo napoved gibanja cene za en mesec vnaprej.

V diskusiji so zajete ključne ugotovitve, ki izhajajo iz teoretičnega in empiričnega dela magistrskega dela. Ugotovitve so obravnavane tudi z vidika uporabnosti za podjetja, pri čemer gre poudarek na predstavitev metod in tehnik napovedovanja cen električne energije. Hkrati so podane tudi omejitve raziskave, ki se med drugim nanašajo na omejitve podatkov, programske opreme, metod in samega modela. Predstavljenih je tudi nekaj predlogov za odpravo izpostavljenih omejitev in ostalih priložnosti za nadaljnje delo.

## LITERATURA IN VIRI

1. Abraham, B. in Ledolter, J. (1983). *Statistical methods for forecasting*. Wiley.
2. Agencija Republike Slovenije za energijo. (2001). *Poročilo o stanju na področju energetike v Sloveniji v letu 2000*. Agencija Republike Slovenije za energijo.
3. Agencija Republike Slovenije za energijo. (2008). *Poročilo o stanju na področju energetike v Sloveniji v letu 2007*. Agencija Republike Slovenije za energijo.
4. Agencija Republike Slovenije za energijo. (2014). *Poročilo o stanju na področju energetike v Sloveniji v letu 2013*. Agencija Republike Slovenije za energijo.

5. Agencija Republike Slovenije za energijo. (2018). *Poročilo o stanju na področju energetike v Sloveniji v letu 2017*. Agencija Republike Slovenije za energijo.
6. Agencija Republike Slovenije za energijo. (2019). *Poročilo o stanju na področju energetike v Sloveniji v letu 2018*. Agencija Republike Slovenije za energijo.
7. Agencija Republike Slovenije za energijo. (2021). *Poročilo o stanju na področju energetike v Sloveniji v letu 2020*. Agencija Republike Slovenije za energijo.
8. Agencija Republike Slovenije za energijo. (2022). *Poročilo o stanju na področju energetike v Sloveniji v letu 2021*. Agencija Republike Slovenije za energijo.
9. Aggarwal, S. K., Saini, L. M. in Kumar, A. (2009). Electricity price forecasting in deregulated markets: A review and evaluation. *International Journal of Electrical Power & Energy Systems*, 31(1), 13–22.
10. Alpaydin, E. (2020). *Introduction to machine learning*. The MIT Press.
11. Altan, A. in Karasu, S. (2019). The effect of kernel values in support vector machine to forecasting performance of financial time series. *The Journal of Cognitive Systems*, 4(1), 17–21.
12. Amjady, N. in Hemmati, M. (2006). Energy price forecasting-problems and proposals for such predictions. *IEEE Power and Energy Magazine*, 4(2), 20–29.
13. Anbazhagan, S. in Kumarappan, N. (2014). Day-ahead deregulated electricity market price forecasting using neural network input featured by DCT. *Energy Conversion and Management*, 78, 711–719.
14. Anderson, E. J., Hu, X. in Winchester, D. (2007). Forward contracts in electricity markets: The Australian experience. *Energy Policy*, 35(5), 3089–3103.
15. Armstrong, J. S. (2001). *Principles of forecasting: A handbook for researchers and practitioners*. Springer.
16. Agencija Republike Slovenije za okolje – ARSO. (brez datuma). *Dnevni vremenski podatki (Arhiv – izbrano obdobje 1. 1. 2017-31. 12. 2018)*.  
<https://meteo.arso.gov.si/met/sl/app/webmet/#webmet==8Sdwx2bhR2cv0WZ0V2bvEGcw9ydIJWblR3LwVnaz9SYtVmYh9iclFGbt9SaulGdugXbsx3cs9mdl5WahxXYyNGapZXZ8tHZv1WYp5mOnMHbvZXZulWYnwCchJXYtVGdlJnOn0UQQdSf>
17. Badillo, S., Banfai, B., Birzele, F., Davydov, I. I., Hutchinson, L., Kam-Thong, T., Siebourg-Polster, J., Steiert, B. in Zhang, J. D. (2020). An introduction to machine learning. *Clinical Pharmacology in Therapeutics*, 107(4), 871–885.
18. Baldick, R. (2012). Wind and energy markets: A case study of Texas. *IEEE Systems Journal*, 6(1), 27–34.
19. Barroso, L. A., Cavalcanti, T. H., Giesbertz, P. in Purchala, K. (2005). Classification of electricity market models worldwide. V *International Symposium CIGRE/IEEE PES, 2005* (str. 9–16). IEEE.
20. Bhattacharyya, S. C. (2011). Introduction to Energy Economics. V S. C. Bhattacharyya (ur.), *Energy Economics* (str. 1–5). Springer-Verlag.
21. Biggar, D. R. in Hesamzadeh, M. R. (2014). *The economics of electricity markets*. Wiley Blackwell.

22. Bigliani, R. (2013). *Reducing risk in oil and gas operations*. <http://documentum.opentext.com/wp-content/uploads/2017/06/minimizing-operational-risk-in-oil-gas-industry.pdf>
23. Bojnec, Š. in Papler, D. (2019). The analysis of liberalisation of the electricity market in Slovenia. *Managerial Economics*, 20(1), 7–26.
24. Böckers, V., Haucap, J. in Heimeshoff, U. (2013). *Benefits of an integrated European electricity market (No. 109)*. Heinrich-Heine-Universität Düsseldorf, Faculty of Economics.
25. Böhringer, C. in Rosendahl, K. E. (2022). Europe beyond coal – An economic and climate impact assessment. *Journal of Environmental Economics and Management*, 113, 102658.
26. Bredin, D. in Muckley, C. (2011). The price forming process in energy markets. V A. Dorsman, W. Westerman, M. B. Karan in Ö. Arslan (ur.), *Financial aspects in energy* (str. 85–107). Springer.
27. British Petroleum. (2021a). *Oil: Statistical Review of World Energy 2021: 70<sup>th</sup> edition*. <https://www.bp.com/content/dam/bp/business-sites/en/global/corporate/pdfs/energy-economics/statistical-review/bp-stats-review-2021-oil.pdf>
28. British Petroleum. (2021b). *Coal: Statistical Review of World Energy 2021: 70<sup>th</sup> edition*. <https://www.bp.com/content/dam/bp/business-sites/en/global/corporate/pdfs/energy-economics/statistical-review/bp-stats-review-2021-coal.pdf>
29. British Petroleum. (2021c). *Natural gas: Statistical Review of World Energy 2021: 70<sup>th</sup> edition*. <https://www.bp.com/content/dam/bp/business-sites/en/global/corporate/pdfs/energy-economics/statistical-review/bp-stats-review-2021-natural-gas.pdf>
30. BSP Energetska borza d. o. o. (brez datuma a). *Trgovanje za dan vnaprej*. <https://www.bsp-southpool.com/trgovanje-za-dan-vnaprej.html>
31. BSP Energetska borza d. o. o. (brez datuma b). *Splošne informacije*. <https://www.bsp-southpool.com/predstavitev-trgovanja-11/splosne-informacije.html>
32. BSP Energetska borza d. o. o. (brez datuma c). *Rezultati trgovanja za dan vnaprej*. <https://www.bsp-southpool.com/trgovalni-podatki.html>
33. Camm, J. D., Cochran, J. J., Fry, M. J. in Ohlmann, J. W. (2020). *Business analytics*. Cengage Learning.
34. Cartea, A. in Figueroa, M. G. (2005). Pricing in electricity markets: a mean reverting jump diffusion model with seasonality. *Applied Mathematical Finance*, 12(4), 313–335.
35. Caruana, R. in Niculescu-Mizil, A. (2006). An empirical comparison of supervised learning algorithms. V *Proceedings of the 23rd international conference on Machine learning* (str. 161–168). Association for Computing Machinery.
36. Cerjan, M., Krželj, I., Vidak, M. in Delimar, M. (2013). A literature review with statistical analysis of electricity price forecasting methods. V I. Kuzle (ur.), *IEEE Eurocon 2013* (str. 756–763). IEEE EUROCON.



37. Cervigni, G. in Perekhodtsev, D. (2013). Wholesale electricity markets. V P. Ranci in G. Cervigni (ur.), *The economics of electricity markets* (str. 18–66). Edward Elgar Publishing.
38. Chatfield, C. (1978). The Holt-Winters forecasting procedure. *Journal of the Royal Statistical Society, Series C (Applied Statistics)*, 27(3), 264–279.
39. Chen, T. in Guestrin, C. (2016). Xgboost: A scalable tree boosting system. V *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining* (str. 785–794). Machinery.
40. Chicco, D., Warrens, M. J. in Jurman, G. (2021). The coefficient of determination R-squared is more informative than SMAPE, MAE, MAPE, MSE and RMSE in regression analysis evaluation. *PeerJ Computer Science*, 7, e623.
41. Chu, Y., Holladay, J. S. in LaRiviere, J. (2017). Opportunity cost pass-through from fossil fuel market prices to procurement costs of the US power producers. *The Journal of Industrial Economics*, 65(4), 842–871.
42. Cramton, P. (2017). Electricity market design. *Oxford Review of Economic Policy*, 33(4), 589–612.
43. Cretì, A. in Fontini, F. (2019). *Economics of electricity, markets, competition and rules*. Cambridge University Press.
44. Cruz, A., Muñoz, A., Zamora, J. L. in Espínola, R. (2011). The effect of wind generation and weekday on Spanish electricity spot price forecasting. *Electric Power Systems Research*, 81(10), 1924–1935.
45. de Mello, R. F. in Ponti, M. A. (2018). Statistical learning theory. V *Machine Learning: A practical approach on the Statistical Learning Theory*, (str. 75–128). Springer.
46. Delgado, J. (2008). *European energy markets: moving in a common direction?* <http://aei.pitt.edu/8390/1/energy%2Dmarkets%2DJdelgado%2D0408.pdf>
47. Deng, S. J. in Oren, S. S. (2006). Electricity derivatives and risk management. *Energy*, 31(6), 940–953.
48. Di Bella, G., Flanagan, M. J., Foda, K., Maslova, S., Pienkowski, A., Stuermer, M. in Toscani, F. G. (2022). Natural gas in Europe: the potential impact of disruptions to supply. *IMF Working Papers*, 145. International Monetary Fund.
49. Dibooglu, S. in AlGudhea, S. N. (2007). All time cheaters versus cheaters in distress: An examination of cheating and oil prices in OPEC. *Economic Systems*, 31(3), 292–310.
50. Douglas, S. in Popova, J. (2008). Storage and the electricity forward premium. *Energy Economics*, 30(4), 1712–1727.
51. Economides, M. J. in Wood, D. A. (2009). The state of natural gas. *Journal of Natural Gas Science and Engineering*, 1(1–2), 1–13.
52. Egging, R. G. in Gabriel, S. A. (2006). Examining market power in the European natural gas market. *Energy Policy*, 34(17), 2762–2778.
53. El Naqa, I. in Murphy, M. J. (2015). What is machine learning? V I. El Naqa, R. Li in M. J. Murphy (ur.), *Machine learning in radiation oncology: theory and applications* (str. 3–11). Springer International Publishing.

54. ENTSO-E. (brez datuma a). *Total load per bidding zone per market time unit*. [https://transparency.entsoe.eu/content/static\\_content/Static%20content/knowledge%20base/data-views/load-domain/Data-view%20Total%20Load%20-%20Day%20Ahead%20-%20Actual.html](https://transparency.entsoe.eu/content/static_content/Static%20content/knowledge%20base/data-views/load-domain/Data-view%20Total%20Load%20-%20Day%20Ahead%20-%20Actual.html)
55. ENTSO-E. (brez datuma b). *Actual Generation per production type*. <https://transparency.entsoe.eu/generation/r2/actualGenerationPerProductionType/show>
56. ENTSO-E. (brez datuma c). *Total Load – Day Ahead/Actual*. [https://transparency.entsoe.eu/load-domain/r2/totalLoadR2/show?name=&defaultValue=false&viewType=TABLE&areaType=BZN&atch=false&dateTime.dateTime=01.01.2017+00:00|CET|DAY&biddingZone.values=CTY|10YSI-ELES-----O!BZN|10YSI-ELES-----O&dateTime.timezone=CET\\_CEST&dateTime.timezone\\_input=CET+\(UTC+1\)+/+CEST+\(UTC+2\)](https://transparency.entsoe.eu/load-domain/r2/totalLoadR2/show?name=&defaultValue=false&viewType=TABLE&areaType=BZN&atch=false&dateTime.dateTime=01.01.2017+00:00|CET|DAY&biddingZone.values=CTY|10YSI-ELES-----O!BZN|10YSI-ELES-----O&dateTime.timezone=CET_CEST&dateTime.timezone_input=CET+(UTC+1)+/+CEST+(UTC+2))
57. ENTSO-E. (brez datuma č). *Total Load – Day Ahead/Actual*. [https://transparency.entsoe.eu/load-domain/r2/totalLoadR2/show?name=&defaultValue=false&viewType=TABLE&areaType=BZN&atch=false&dateTime.dateTime=01.01.2018+00:00|CET|DAY&biddingZone.values=CTY|10YSI-ELES-----O!BZN|10YSI-ELES-----O&dateTime.timezone=CET\\_CEST&dateTime.timezone\\_input=CET+\(UTC+1\)+/+CEST+\(UTC+2\)](https://transparency.entsoe.eu/load-domain/r2/totalLoadR2/show?name=&defaultValue=false&viewType=TABLE&areaType=BZN&atch=false&dateTime.dateTime=01.01.2018+00:00|CET|DAY&biddingZone.values=CTY|10YSI-ELES-----O!BZN|10YSI-ELES-----O&dateTime.timezone=CET_CEST&dateTime.timezone_input=CET+(UTC+1)+/+CEST+(UTC+2))
58. Escribano, A., Ignacio Peña, J. in Villaplana, P. (2011). Modelling electricity prices: International evidence. *Oxford Bulletin of Economics and Statistics*, 73(5), 622–650.
59. EURACOAL. (brez datuma a). *Coal*. <https://euracoal.eu/coal/>
60. EURACOAL. (brez datuma b). *Why is there no lignite market?* <https://euracoal.eu/coal/why-is-there-no-lignite-market/>
61. European Commission. (brez datuma). *Energy union*. [https://energy.ec.europa.eu/topics/energy-strategy/energy-union\\_en](https://energy.ec.europa.eu/topics/energy-strategy/energy-union_en)
62. Eurostat. (2021, 10. avgust). *Coal production and consumption decreased by a third in 2 years*. <https://ec.europa.eu/eurostat/web/products-eurostat-news/-/ddn-20210810-1>
63. Eurostat. (2022a). *Oil and petroleum products – a statistical review*. [https://ec.europa.eu/eurostat/statistics-explained/index.php?title=Oil\\_and\\_petroleum\\_products\\_-\\_a\\_statistical\\_overview#Production\\_of\\_crude\\_oil](https://ec.europa.eu/eurostat/statistics-explained/index.php?title=Oil_and_petroleum_products_-_a_statistical_overview#Production_of_crude_oil)
64. Eurostat. (2022b). *Coal production and consumption statistics*. [https://ec.europa.eu/eurostat/statistics-explained/index.php?title=Coal\\_production\\_and\\_consumption\\_statistics](https://ec.europa.eu/eurostat/statistics-explained/index.php?title=Coal_production_and_consumption_statistics)
65. Eurostat. (2022c). *Natural gas supply statistics*. [https://ec.europa.eu/eurostat/statistics-explained/index.php?title=Natural\\_gas\\_supply\\_statistics#Consumption\\_trends](https://ec.europa.eu/eurostat/statistics-explained/index.php?title=Natural_gas_supply_statistics#Consumption_trends)
66. Eurostat. (2022č). *Nuclear energy statistics*. [https://ec.europa.eu/eurostat/statistics-explained/index.php?title=Nuclear\\_energy\\_statistics#Nuclear\\_heat\\_and\\_gross\\_electricity\\_production](https://ec.europa.eu/eurostat/statistics-explained/index.php?title=Nuclear_energy_statistics#Nuclear_heat_and_gross_electricity_production)
67. Eurostat. (2023a). *Electricity production, consumption and market overview*. <https://ec.europa.eu/eurostat/statistics->

- explained/index.php?title=Electricity\_production,\_consumption\_and\_market\_overview#Electricity\_generation
68. Eurostat. (2023b). *Renewable energy statistics*. [https://ec.europa.eu/eurostat/statistics-explained/index.php?title=Renewable\\_energy\\_statistics#Share\\_of\\_renewable\\_energy\\_more\\_than\\_doubled\\_between\\_2004\\_and\\_2020](https://ec.europa.eu/eurostat/statistics-explained/index.php?title=Renewable_energy_statistics#Share_of_renewable_energy_more_than_doubled_between_2004_and_2020)
  69. Evropska komisija. (2022). *Sporočilo Komisije Evropskemu parlamentu, Svetu,, Evropskemu ekonomsko-socialnemu odboru in odboru regij: načrt REPowerEU, SWD(2022) 230 final*. [https://eur-lex.europa.eu/resource.html?uri=cellar:fc930f14-d7ae-11ec-a95f-01aa75ed71a1.0011.02/DOC\\_1&format=PDF](https://eur-lex.europa.eu/resource.html?uri=cellar:fc930f14-d7ae-11ec-a95f-01aa75ed71a1.0011.02/DOC_1&format=PDF)
  70. Fan, J., Wang, X., Wu, L., Zhou, H., Zhang, F., Yu, X., Lu, X. in Xiang, Y. (2018). Comparison of support vector machine and extreme gradient boosting for predicting daily global solar radiation using temperature and precipitation in humid subtropical climates: A case study in China. *Energy Conversion and Management*, 164(8), 102–111.
  71. Favennec, J.-P. (2022). Economics of Oil Refining. V M. Hafner in G. Luciani (ur.), *The Palgrave handbook of international energy economics* (str. 59–74). Palgrave Macmillan.
  72. Fernández Alvarez, C. (2022). *The trading and price discovery for coal*. V M. Hafner in G. Luciani (ur.), *The Palgrave handbook of international energy economics* (str. 395–407). Springer Nature.
  73. Filippini, M., Hrovatin, N. in Zorič, J. (2004). Efficiency and regulation of the Slovenian electricity distribution companies. *Energy Policy*, 32(3), 335–344.
  74. Fusaro, P. C. (2005). Green trading: Convergence of the capital markets and the environment. V P. C. Fusaro in M. Yuen (ur.), *Green Trading Markets* (str. 1–14). Elsevier.
  75. Garcia, R. C., Contreras, J., Van Akkeren, M. in Garcia, J. B. C. (2005). A GARCH forecasting model to predict day-ahead electricity prices. *IEEE Transactions on Power Systems*, 20(2), 867–874.
  76. Gilchrist, W. (1974). Statistical forecasting—the state of the art. *Omega*, 2(6), 733–750.
  77. Goldemberg, J. (2004). The case for renewable energies. V *Renewable Energy* (str. 31–42). Routledge.
  78. González, C., Mira-McWilliams, J. in Juárez, I. (2015). Important variable assessment and electricity price forecasting based on regression tree models: classification and regression trees, Bagging and Random Forests. *IET Generation, Transmission & Distribution*, 9(11), 1120–1128.
  79. Goto, M. in Karolyi, G. A. (2004). *Understanding electricity price volatility within and across markets*. <https://econpapers.repec.org/scripts/redir.pf?u=http%3A%2F%2Fwww.cob.ohio-state.edu%2Ffin%2Fdice%2Fpapers%2F2004%2F2004-12.pdf;h=repec:ecl:ohidic:2004-12>
  80. Green, R. J. (2008). Electricity wholesale markets: designs now and in a low-carbon future. *The Energy Journal*, 29(Special Issue 2), 95–124.
  81. Green, R. in Vasilakos, N. (2010). Market behaviour with large amounts of intermittent generation. *Energy Policy*, 38(7), 3211–3220.

82. Hafner, M., Karbuz, S., Esnault, B. in Andaloussi, H. E. (2008). Long-term natural gas supply to Europe: Import potential, infrastructure needs and investment promotion. *Energy & Environment*, 19(8), 1131–1153.
83. Hafner, M. in Luciani, G. (ur.). (2022). *The Palgrave Handbook of International Energy Economics*. Springer Nature.
84. Henriot, A. (2012). *Market design with wind: managing low-predictability in intraday markets*. [https://cadmus.eui.eu/bitstream/handle/1814/24556/RSCAS\\_2012\\_63.pdf?sequence=1&isAllowed=y](https://cadmus.eui.eu/bitstream/handle/1814/24556/RSCAS_2012_63.pdf?sequence=1&isAllowed=y)
85. Ho, S. L., Xie, M. in Goh, T. N. (2002). A comparative study of neural network and Box-Jenkins ARIMA modeling in time series prediction. *Computers & Industrial Engineering*, 42(2–4), 371–375.
86. Howison, S. in Coulon, M. (2009). Stochastic behaviour of the electricity bid stack: from fundamental drivers to power prices. *Journal of Energy Markets*, 2(1), 29–69.
87. Hrovatin, N., Pittman, R. in Zorić, J. (2009). Organisation and reforms of the electricity sector in Slovenia. *Utilities Policy*, 17(1), 134–143.
88. Hyndman, R. J. in Athanasopoulos, G. (2018). *Forecasting: principles and practice* (2. izd.). OTexts.
89. IBM. (brez datuma). *What is supervised learning?* <https://www.ibm.com/cloud/learn/supervised-learning#toc-unsupervis-Fo3jDcmY>
90. Imsirovic, A. (2022). *The trading and price discovery for crude oil*. V M. Hafner in G. Luciani (ur.), *The Palgrave handbook of international energy economics* (str. 327–359). Springer Nature.
91. Iovino, F. in Tsitsianis, N. (2020). *Changes in European energy markets: What the evidence tells us*. Emerald Publishing.
92. Jabeur, S. B., Mefteh-Wali, S. in Viviani, J. L. (2021). Forecasting gold price with the XGBoost algorithm and SHAP interaction values. *Annals of Operations Research*, 1–21.
93. Jacobs, K., Li, Y. in Pirrong, C. (2017). Supply, demand, and risk premiums in electricity markets. *Journal of Banking & Finance*, 135, 106390.
94. Jakaša, T., Andročec, I. in Sprčić, P. (2011). Electricity price forecasting—ARIMA model approach. V *2011 8th International Conference on the European Energy Market (EEM)* (str. 222–225). IEEE.
95. Jędrzejewski, A., Lago, J., Marcjasz, G. in Weron, R. (2022). Electricity price forecasting: The dawn of machine learning. *IEEE Power and Energy Magazine*, 20(3), 24–31.
96. Jonsson, T., Pinson, P., Nielsen, H. A., Madsen, H. in Nielsen, T. S. (2012). Forecasting electricity spot prices accounting for wind power predictions. *IEEE Transactions on Sustainable Energy*, 4(1), 210–218.
97. Jouvét, P.-A. in Solier, B. (2013). An overview of CO<sub>2</sub> cost pass-through to electricity prices in Europe. *Energy Policy*, 61, 1370–1376.
98. Karan, M. B. in Kazdağlı, H. (2011). The development of energy markets in Europe. V A. Dorsman, W. Westerman, M. B. Karan in Ö. Arslan, (ur.), *Financial Aspects in Energy* (str. 11–32). Springer.

99. Kardoš, J., Holt, T., Schenk, O., Fazio, V., Fabietti, L. in Spazzini, F. (2021). High-performance data analytics techniques for power markets simulation. V *2021 International Conference on Smart Energy Systems and Technologies (SEST)* (str. 1–6). IEEE.
100. Kijewska, A. in Bluszcz, A. (2016). Analysis of greenhouse gas emissions in the European Union member states with the use of an agglomeration algorithm. *Journal of Sustainable Mining*, 15(4), 133–142.
101. Kirchgässner, G., Wolters, J. in Hassler, U. (2007). *Introduction to modern time series analysis*. Springer.
102. Kirschen, D. S. in Strbac, G. (2004). *Fundamentals of Power System Economics*. John Wiley & Sons.
103. Klopčič, A. L., Hojnik, J. in Bojnec, Š. (2021). Razvoj maloprodajnega trga električne energije v Sloveniji. *Elektrotehniški vestnik*, 88(4), 163–173.
104. Klopčič, A. L., Hojnik, J. in Bojnec, Š. (2022). What is the state of development of retail electricity markets in the EU? *The Electricity Journal*, 35(3), 1–10.
105. Kristiansen, T. (2011). Power trading analytics and forecasting in Germany. *The Electricity Journal*, 24(8), 41–55.
106. Lago, J., De Ridder, F. in De Schutter, B. (2018a). Forecasting spot electricity prices: Deep learning approaches and empirical comparison of traditional algorithms. *Applied Energy*, 221, 386–405.
107. Lago, J., De Ridder, F., Vrancx, P. in De Schutter, B. (2018b). Forecasting day-ahead electricity prices in Europe: The importance of considering market integration. *Applied energy*, 211(C), 890–903.
108. Larsen, E. R. in Bunn, D. W. (1999). Deregulation in electricity: understanding strategic and regulatory risk. *Journal of the Operational Research Society*, 50(4), 337–344.
109. Li, G., Liu, C. C., Mattson, C. in Lawarrée, J. (2007). Day-ahead electricity price forecasting in a grid environment. *IEEE Transactions on Power Systems*, 22(1), 266–274.
110. Majid, R. in Mir, S. A. (2018). Advances in statistical forecasting methods: An overview. *Economic Affairs*, 63(4), 815–831.
111. Mandal, P., Senjyu, T., Uezato, K. in Funabashi, T. (2005). Several-hours-ahead electricity price and load forecasting using neural networks. V *IEEE Power Engineering Society General Meeting, 2005* (str. 2146–2153). IEEE.
112. Marcu, A. in Cecchetti, F. (2022). The trading of carbon. V M. Hafner in G. Luciani (ur.), *The Palgrave handbook of international energy economics* (str. 439–471). Springer Nature.
113. Mathiesen, P., Kleissl, J. in Collier, C. (2013). Case studies of solar forecasting with the weather research and forecasting model at GL-Garrad Hassan. V J. Kleissl (ur.), *Solar Energy Forecasting and Resource Assessment* (str. 357–382). Academic Press.
114. Mäntysaari, P. (2015). EU electricity trade law: *The legal tools of electricity producers in the internal market*. Springer.

115. Milstein, I. in Tishler, A. (2015). Can price volatility enhance market power? The case of renewable technologies in competitive electricity markets. *Resource and Energy Economics*, 41(C), 70–90.
116. Moffatt Associates Partnership. (2008). *EnergyViewPoints: Developing energy markets*. [http://www.moffatt-associates.com/energy\\_services/forecasting\\_market\\_trends/energy\\_viewpoints/documents/17/17\\_full.pdf](http://www.moffatt-associates.com/energy_services/forecasting_market_trends/energy_viewpoints/documents/17/17_full.pdf)
117. Morales Pedraza, J. (2015a). *Electrical energy generation in Europe*. Springer International Publishing.
118. Morales Pedraza, J. (2015b). *Electrical energy generation in Europe: The current and future role of conventional energy sources in the regional generation of electricity*. Springer.
119. Pampel, F. C. (2011). Support for nuclear energy in the context of climate change: Evidence from the European Union. *Organization & Environment*, 24(3), 249–268.
120. Pepermans, G. (2019). European energy market liberalization: Experiences and challenges. *International Journal of Economic Policy Studies*, 13(1), 3–26.
121. Pospiech, M. in Felden, C. (2016). Big Data -- A theory model. V X. B. Tung in R. H. Sprague (ur.), *Proceedings of the 49th Hawaii International Conference on System Sciences* (str. 5012–5021). IEEE.
122. Prabavathi, M., in Gnanadass, R. (2015). Energy bidding strategies for restructured electricity market. *International Journal of Electrical Power & Energy Systems*, 64, 956–966.
123. Pravila za izvajanje izravnalnega trga z elektriko. Uradni list RS, št. 97/14, 28/17 in 161/22.
124. RapidMiner. (brez datuma). *Time series analytics: Time series forecasting and modelling*. <https://academy.rapidminer.com/learn/course/time-series-analytics/time-series-analytics/time-series-forecasting-and-modelling?page=1>
125. RapidMiner Documentation. (brez datuma a). (*Holt – Winters: (Time Series)*). [https://docs.rapidminer.com/9.9/studio/operators/modeling/time\\_series/forecasting/holt-winters\\_trainer.html](https://docs.rapidminer.com/9.9/studio/operators/modeling/time_series/forecasting/holt-winters_trainer.html)
126. RapidMiner Documentation. (brez datuma b). *ARIMA (Time Series)*. [https://docs.rapidminer.com/9.4/studio/operators/modeling/time\\_series/forecasting/arima\\_trainer.html](https://docs.rapidminer.com/9.4/studio/operators/modeling/time_series/forecasting/arima_trainer.html)
127. RapidMiner Documentation. (brez datuma c). *Apply Forecast: (Time Series)*. [https://docs.rapidminer.com/9.7/studio/operators/modeling/time\\_series/forecasting/apply\\_forecast.html](https://docs.rapidminer.com/9.7/studio/operators/modeling/time_series/forecasting/apply_forecast.html)
128. Reguant, M. (2014). Complementary bidding mechanisms and startup costs in electricity markets. *The Review of Economic Studies*, 81(4), 1708–1742.
129. Sansom, D. C., Downs, T. in Saha, T. K. (2003). Evaluation of support vector machine based forecasting tool in electricity price forecasting for Australian national electricity market participants. *Journal of Electrical and Electronics Engineering*, 22(3), 227–234.

130. Scharff, R. in Amelin, M. (2016). Trading behaviour on the continuous intraday market Elbas. *Energy Policy*, 88(C), 544–557.
131. Serati, M., Manera, M. in Plotegher, M. (2008). Modeling electricity prices: from the state of the art to a draft of a new proposal. *SSRN Electronic Journal*, 1–26.
132. Sgarlato, R. in Ziel, F. (2022). The role of weather predictions in electricity price forecasting beyond the day-ahead horizon. *IEEE Transactions on Power Systems*, 38(3), 2500–2511.
133. Shah, D. in Chatterjee, S. (2020). A comprehensive review on day-ahead electricity market and important features of world's major electric power exchanges. *International Transactions on Electrical Energy Systems*, 30(7), e12360.
134. Shavlik, J. W., Dietterich, T. in Dietterich, T. G. (1990). *Readings in machine learning*. Morgan Kaufmann.
135. Shinde, P. in Amelin, M. (2019). A literature review of intraday electricity markets and prices. V *2019 IEEE Milan PowerTech* (str. 1–6). IEEE.
136. Singhal, D. in Swarup, K. S. (2011). Electricity price forecasting using artificial neural networks. *International Journal of Electrical Power & Energy Systems*, 33(3), 550–555.
137. Skantze, P. L. in Ilic, M. D. (2001). *Valuation, hedging and speculation in competitive electricity markets: a fundamental approach*. Springer Science & Business Media.
138. Speight, J. G. (2018). *Natural gas: a basic handbook* (2. izd.). Gulf Professional Publishing.
139. Speight, J. G. (2021). *Coal-fired power generation handbook* (2. izd.). John Wiley & Sons.
140. Thielemann, T., Schmidt, S. in Gerling, J. P. (2007). Lignite and hard coal: Energy suppliers for world needs until the year 2100 – An outlook. *International Journal of Coal Geology*, 72(1), 1–14.
141. Tschora, L., Pierre, E., Plantevit, M., & Robardet, C. (2022). Electricity price forecasting on the day-ahead market using machine learning. *Applied Energy*, 313, 1–14.
142. Van Hecke, K. (2007). Nuclear energy in the European Union. *Studia Diplomatica*, 60(2), 131–155.
143. Vani, T. (2021). Impetus to machine learning in cardiac disease diagnosis. V K. Chauhan in R. K. Chauhan (ur.), *Image Processing for Automated Diagnosis of Cardiac Diseases* (str. 99–116). Academic Press.
144. vom Scheidt, F., Medinová, H., Ludwig, N., Richter, B., Staudt, P. in Weinhardt, C. (2020). Data analytics in the electricity sector – A quantitative and qualitative literature review. *Energy and AI*, 1, 100009.
145. Weron, R. (2014). Electricity price forecasting: A review of the state-of-the-art with a look into the future. *International Journal of Forecasting*, 30(4), 1030–1081.
146. Weron, R. in Misiorek, A. (2006). *Short-term electricity price forecasting with time series models: A review and evaluation*. [http://prac.im.pwr.edu.pl/~hugo/RePEc/wuu/wpaper/HSC\\_06\\_01.pdf](http://prac.im.pwr.edu.pl/~hugo/RePEc/wuu/wpaper/HSC_06_01.pdf)

147. Wu, B., Wang, L., Lv, S. X. in Zeng, Y-R. (2021). Effective crude oil price forecasting using new text-based and big-data-driven model. *Measurement*, 168, 108468.
148. Wu, K., Chai, Y., Zhang, X. in Zhao, X. (2022). Research on power price forecasting based on PSO-XGBoost. *Electronics*, 11(22), 3763.
149. Xie, H., Chen, S., Lai, C., Ma, G. in Huang, W. (2022). Forecasting the clearing price in the day-ahead spot market using eXtreme Gradient Boosting. *Electrical Engineering*, 104(1), 1–15.
150. Yan, X. in Chowdhury, N. A. (2014). Mid-term electricity market clearing price forecasting: A multiple SVM approach. *International Journal of Electrical Power & Energy Systems*, 58, 206–214.
151. Zhao, X., Li, Q., Xue, W., Zhao, Y., Zhao, H. in Guo, S. (2022). Research on ultra-short-term load forecasting based on real-time electricity price and window-based XGBoost model. *Energies*, 15(19), 7367.
152. Ziel, F. in Steinert, R. (2018). Probabilistic mid- and long-term electricity price forecasting. *Renewable and Sustainable Energy Reviews*, 94, 251–266.