

ЖАҢАРТЫЛАТЫН ЭНЕРГИЯ ГЕНЕРАЦИЯСЫН БОЛЖАУ: ARIMA, XGBOOST ЖӘНЕ ТЕРЕҢ ОҚЫТУҒА ҰҚСАС ПРОКСИ-МОДЕЛЬДІ САЛЫСТЫРУ

¹С.Ә. Тұрғын*^{ID}, ²Г.Ж. Таганова^{ID}

^{1,2}Астана халықаралық университеті, Астана қ., Қазақстан

*e-mail: b67689@gmail.com

С.Ә. Тұрғын – АТИЖМ-нің студенті, Астана халықаралық университеті, Астана қ., Қазақстан, e-mail: b67689@gmail.com, <https://orcid.org/0009-0009-9605-9982>

Г.Ж. Таганова – аға оқытушы, ғылыми жетекші, Астана халықаралық университеті, Астана қ., Қазақстан, e-mail: guldana.kileuzhanova@gmail.com, <https://orcid.org/0000-0001-6139-6270>

Аңдатпа. Жаңартылатын энергия көздерінен өндірілетін электр энергиясын қысқа мерзімді болжау электр желісін сенімді басқару, энергия балансын жоспарлау және генерация көлеміндегі ауытқуларды алдын ала бағалау үшін маңызды. Бұл мақалада үш тәсіл салыстырылады: классикалық ARIMA моделі, градиенттік бустингке негізделген XGBoost алгоритмі және LSTM логикасына ұқсас терезелік прокси-модель. Зерттеу бакалавриат деңгейіндегі оқу-зерттеу жұмысы ретінде орындалды және синтетикалық сағаттық деректерге негізделді. Деректер 2023 жылға арналған күн және жел генерациясының тәуліктік, маусымдық және стохастикалық заңдылықтарын имитациялайды. Модельдер алғашқы он бір айдағы деректер бойынша оқытылып, соңғы отыз күндік тестілік кезеңде бағаланды. Нәтижелер бойынша күн генерациясын болжауда терезелік прокси-модель ең төмен RMSE мәнін көрсетті (21,50 МВт), ал XGBoost нәтижесі оған жақын болды (23,44 МВт). Жел генерациясында екі модельдің нәтижелері шамалас болды, бұл жел ресурсының жоғары стохастикалық сипатын көрсетеді. Жұмыста MAPE метрикасының нөлге жақын генерация мәндері кезінде тұрақсыз болатыны көрсетіліп, RMSE және MAE метрикаларын негізгі бағалау көрсеткіштері ретінде қолдану ұсынылды.

Түйін сөздер: жаңартылатын энергия, күн генерациясы, жел генерациясы, уақыттық қатарлар, ARIMA, XGBoost, LSTM-прокси, машиналық оқыту, RMSE, MAE, MAPE.

ПРОГНОЗИРОВАНИЕ ГЕНЕРАЦИИ ВОЗОБНОВЛЯЕМОЙ ЭНЕРГИИ: СРАВНЕНИЕ ARIMA, XGBOOST И ПРОКСИ-МОДЕЛИ, ОСНОВАННОЙ НА ЛОГИКЕ ГЛУБОКОГО ОБУЧЕНИЯ

¹С.А. Турғын*, ²Г.Ж. Таганова

^{1,2}Международный университет Астана, г. Астана, Казахстан

*e-mail: b67689@gmail.com

С.А. Турғын – студент ВШИТИ, Международный университет Астана, г. Астана, Казахстан, e-mail: b67689@gmail.com, <https://orcid.org/0009-0009-9605-9982>

Г.Ж. Таганова – старший преподаватель, научный руководитель, Международный университет Астана, г. Астана, Казахстан, e-mail: guldana.kileuzhanova@gmail.com, <https://orcid.org/0000-0001-6139-6270>

Аннотация. Точное краткосрочное прогнозирование генерации из возобновляемых источников энергии важно для управления энергосистемой, планирования баланса и снижения рисков, связанных с изменчивостью солнечной и ветровой генерации. В статье сравниваются три подхода: классическая модель ARIMA, алгоритм градиентного бустинга XGBoost и упрощённая оконная прокси-модель, имитирующая логику LSTM-подхода. Исследование

выполнено как учебно-исследовательская работа бакалавра и основано на синтетических почасовых данных за 2023 год. Данные сгенерированы с учётом типичных суточных, сезонных и стохастических закономерностей солнечной и ветровой генерации. Модели обучались на данных первых одиннадцати месяцев и тестировались на последних тридцати днях. Результаты показали, что для солнечной генерации прокси-модель дала наименьшее значение RMSE (21,50 МВт), тогда как XGBoost показал близкий результат (23,44 МВт). Для ветровой генерации результаты моделей оказались почти одинаковыми, что связано с высокой стохастичностью ветрового ресурса. Также показано, что MAPE может быть нестабильной метрикой при нулевых и близких к нулю значениях генерации, поэтому RMSE и MAE являются более надёжными показателями для сравнения моделей.

Ключевые слова: возобновляемая энергия, солнечная генерация, ветровая генерация, временные ряды, ARIMA, XGBoost, LSTM-прокси, машинное обучение, RMSE, MAE, MAPE.

FORECASTING RENEWABLE ENERGY GENERATION: COMPARISON OF ARIMA, XGBOOST, AND A DEEP-LEARNING-INSPIRED PROXY MODEL

¹S. Turgyn*, ²G.Zh. Taganova

^{1,2}Astana International University, Astana, Kazakhstan

*e-mail: b67689@gmail.com

S. Turgyn – student at the Higher School of Economics, Astana International University, Astana, Kazakhstan, e-mail: b67689@gmail.com, <https://orcid.org/0009-0009-9605-9982>

G.Zh. Taganova – Senior lecturer, Scientific Supervisor, Astana International University, Astana, Kazakhstan, e-mail: guldana.kileuzhanova@gmail.com, <https://orcid.org/0000-0001-6139-6270>

Abstract. Accurate short-term forecasting of renewable energy generation is important for power-system operation, balancing, and energy planning. This paper compares three forecasting approaches: the classical ARIMA model, the XGBoost gradient-boosting algorithm, and a simplified window-based proxy model inspired by the logic of LSTM sequence modelling. The study is designed as an undergraduate research paper and uses synthetic hourly data for 2023. The dataset imitates typical daily, seasonal, and stochastic patterns of solar and wind generation. The models were trained on the first eleven months and evaluated on the final thirty-day hold-out period. For solar generation, the proxy model achieved the lowest RMSE (21.50 MW), while XGBoost produced a competitive result (23.44 MW). For wind generation, both approaches showed similar performance, which reflects the stochastic nature of wind power. The study also demonstrates that MAPE may be unstable when generation values are zero or close to zero; therefore, RMSE and MAE are recommended as the main comparison metrics.

Keywords: renewable energy, solar generation, wind generation, time series, ARIMA, XGBoost, LSTM-proxy, machine learning, RMSE, MAE, MAPE.

Кіріспе. Жаңартылатын энергия көздерінің үлесі әлемдік энергетикалық жүйеде жыл сайын артып келеді. Күн фотоэлектрлік станциялары мен жел электр станциялары экологиялық тұрғыдан тиімді болғанымен, олардың генерация көлемі ауа райына, тәуліктік циклге және маусымдық өзгерістерге тәуелді. Сондықтан мұндай энергия көздерінен алынатын электр энергиясын алдын ала болжау электр желісінің тұрақты жұмысы үшін маңызды.

Күн генерациясы көбіне тәуліктік және маусымдық заңдылықтарға бағынады: күндіз жоғары, түнде нөлге жақын болады, ал қыс мезгілінде орташа өндіріс төмендейді. Жел генерациясы күрделірек сипатқа ие, себебі жел жылдамдығы кездейсоқ ауытқуларға және қысқа мерзімді метеорологиялық құбылыстарға тәуелді. Осы себепті күн және жел генерациясын болжау уақыттық қатарларды талдау, машиналық оқыту және терең оқыту әдістерін қолдануды талап етеді.

Бұл жұмыстың мақсаты — синтетикалық сағаттық деректер негізінде ARIMA, XGBoost және LSTM логикасына ұқсас терезелік прокси-модельдің болжау дәлдігін салыстыру. Зерттеу студенттік оқу-зерттеу жұмысы ретінде орындалғандықтан, негізгі назар күрделі өндірістік жүйені құруға емес, әртүрлі модельдердің жұмыс қағидаларын түсіндіруге және олардың нәтижелерін салыстыруға бағытталды.

Тақырып бойынша әдеби шолу. Жаңартылатын энергия генерациясын болжау саласында статистикалық модельдер, машиналық оқыту алгоритмдері және терең оқыту архитектуралары кеңінен қолданылады. Ерте зерттеулерде ARIMA, ARX және басқа авторегрессиялық модельдер қысқа мерзімді күн генерациясын болжау үшін тиімді базалық әдіс ретінде қарастырылды. Мысалы, Bacher және әріптестері күн фотоэлектрлік жүйелерінің 36 сағатқа дейінгі болжамында авторегрессиялық тәсілдердің пайдалы екенін көрсетті (Bacher et al., 2009: 1772).

Күн энергиясын болжауға арналған шолу жұмыстарында болжау дәлдігіне деректер сапасы, уақыттық ажыратымдылық, ауа райы айнымалылары және бағалау метрикалары тікелей әсер ететіні атап өтіледі. Antonanzas және әріптестері фотоэлектрлік қуатты болжауда статистикалық, машиналық оқыту және гибридік әдістердің қолданылуын жүйеледі (Antonanzas et al., 2016: 78). Voyant және әріптестері машиналық оқыту әдістері күн радиациясын болжауда классикалық модельдерге қарағанда күрделі сызықтық емес тәуелділіктерді жақсы ұстай алатынын көрсетті (Voyant et al., 2017: 569). Sobri және әріптестері күн фотоэлектрлік генерациясын болжауда жасанды нейрондық желілер, тірек векторлық машиналар, регрессиялық модельдер және ансамбльдік тәсілдер жиі қолданылатынын атап өтті (Sobri et al., 2018: 459).

Жел генерациясын болжау күн генерациясына қарағанда күрделірек болуы мүмкін, себебі жел жылдамдығы мен бағыты жоғары стохастикалық сипатқа ие. Жел энергетикасы бойынша шолу еңбектерінде қысқа мерзімді болжам үшін тарихи генерация, метеорологиялық деректер және лагтық белгілерді бірге қолдану ұсынылады (Jung, Broadwater, 2014: 762). Сондықтан жел генерациясын болжауда тек уақыттық қатарға сүйену жеткіліксіз болуы мүмкін, ал сыртқы ауа райы белгілерін қосу модель сапасын арттыра алады.

Машиналық оқыту әдістерінің ішінде шешім ағаштарына негізделген ансамбльдік модельдер практикалық есептерде жиі қолданылады. XGBoost алгоритмі градиенттік бустинг қағидасына негізделеді және кестелік деректердегі сызықтық емес тәуелділіктерді тиімді үйрене алады (Chen, Guestrin, 2016: 785). Энергетикалық болжау есептерінде XGBoost, Random Forest және LightGBM сияқты модельдер лагтық белгілермен, жылжымалы орташа мәндермен және күнтізбелік белгілермен бірге қолданылғанда тұрақты нәтиже береді (Lago et al., 2021: 116983).

Терең оқыту әдістері уақыттық қатарлардағы күрделі тәуелділіктерді үйрену қабілетімен ерекшеленеді. LSTM желісі ұзақ және қысқа мерзімді тәуелділіктерді сақтау үшін арнайы қақпалық механизмдерді қолданады (Hochreiter, Schmidhuber, 1997: 1735). Qing және Niu LSTM моделін күн радиациясын бір күн бұрын болжау міндетінде қолданып, ауа райы болжамдары мен тарихи деректерді бірге пайдалану нәтиженің жақсаруына әсер ететінін көрсетті (Qing, Niu, 2018: 461). GRU, CNN-LSTM және басқа нейрондық архитектуралар да жаңартылатын энергияны болжауда қолданылады, бірақ оларды сапалы оқыту үшін жеткілікті көлемдегі деректер мен есептеу ресурстары қажет.

Соңғы жылдары Transformer негізіндегі модельдер ұзын уақыттық қатарлармен жұмыс істеуге бейімделіп келеді. Informer моделі ұзақ реттіліктерді болжау үшін тиімді attention механизмін ұсынды (Zhou et al., 2021: 11106), ал Temporal Fusion Transformer көпқадамды уақыттық болжамда интерпретацияланатын архитектура ретінде қарастырылады (Lim et al., 2021: 1748). Дегенмен мұндай модельдер студенттік деңгейдегі шағын эксперименттер үшін күрделі болуы мүмкін.

Болжам нәтижелерін бағалау кезінде RMSE, MAE және MAPE метрикалары жиі

қолданылады. Hong және әріптестері энергетикалық болжауда тек бір метрикаға сүйенбей, модель сапасын бірнеше көрсеткіш арқылы бағалау маңызды екенін атап өтті (Hong et al., 2016: 896). Осы әдебиеттерге сүйене отырып, бұл мақалада студенттік зерттеу деңгейінде үш тәсіл салыстырылады: классикалық ARIMA, лагтық белгілерге негізделген XGBoost және LSTM логикасына ұқсас терезелік прокси-модель.

Деректер жиыны. Зерттеуде 2023 күнтізбелік жылына арналған синтетикалық сағаттық деректер жиыны пайдаланылды. Жалпы бақылаулар саны 8760 сағатты құрады. Деректер нақты ENTSO-E деректерінен тікелей алынған жоқ; олар күн және жел генерациясының жалпы статистикалық және маусымдық қасиеттерін имитациялау мақсатында жасалды. Бұл тәсіл студенттік зерттеу үшін модельдерді қауіпсіз және қайталанатын ортада салыстыруға мүмкіндік береді.

Күн генерациясы үшін тәуліктік синусоидалық қисық, маусымдық модуляция және кездейсоқ шу қолданылды. Түнгі уақытта генерация нөлге жақын, ал күндіз жоғары мәндерге ие болады. Жел генерациясы үшін авторегрессивті шу және маусымдық компонент енгізілді, себебі жел ресурсы күн генерациясына қарағанда әлдеқайда стохастикалық сипатқа ие.

Машиналық оқыту модельдері үшін келесі белгілер қолданылды: лагтық белгілер (t-1, t-2, t-3, t-24, t-48, t-168), 24 сағаттық жылжымалы орташа мән және күнтізбелік белгілер (сағат, ай, апта күні). Терезелік прокси-модель үшін соңғы 72 сағаттық деректер терезесі пайдаланылды.

Материалдар мен зерттеу әдістері. ARIMA моделі күн генерациясының күнделікті жиынтық мәндеріне қолданылды. Бұл модель осы жұмыста қарапайым статистикалық базалық тәсіл ретінде қарастырылды. ARIMA нәтижелері сағаттық XGBoost және прокси-модель нәтижелерімен тікелей тең деңгейде емес, базалық салыстыру ретінде ғана талданды.

XGBoost моделі күн және жел генерациясының сағаттық қатарлары үшін бөлек оқытылды. Модель лагтық және күнтізбелік белгілерді пайдаланып, болашақ генерация мәнін болжады. Негізгі гиперпараметрлер ретінде 300 ағаш, максималды тереңдік 6 және оқу жылдамдығы 0,05 қолданылды.

Терең оқытуға ұқсас прокси-модель толық LSTM желісі емес. Ол соңғы 72 сағаттық терезеден алынған сызықтық емес белгілер мен статистикалық сипаттамаларға негізделді. Бұл тәсіл LSTM желісінің уақыттық тәуелділіктермен жұмыс істеу идеясын жеңілдетілген түрде көрсету үшін қолданылды. Мұндай модель оқу-зерттеу мақсатында түсінікті және есептеу жағынан жеңіл болып табылады.

Модельдердің сапасын бағалау үшін RMSE, MAE және MAPE метрикалары қолданылды. Негізгі салыстыру RMSE және MAE бойынша жүргізілді, себебі MAPE нөлге жақын мәндер кезінде тұрақсыз нәтиже беруі мүмкін.

Бағалау хаттамасы. Деректер жиыны уақыт бойынша екі бөлікке бөлінді. 2023 жылғы қаңтар–қараша аралығындағы деректер модельдерді оқыту үшін, ал желтоқсан айының соңғы 30 күні тестілік кезең ретінде пайдаланылды. Мұндай бөлу уақыттық қатарлар үшін дұрыс тәсіл болып саналады, себебі болашақ деректер оқыту кезеңіне араластырылмайды.

Сағаттық модельдер үшін тест кезеңі 720 бақылаудан тұрды. ARIMA моделі күнделікті жиынтық мәндермен жұмыс істегендіктен, оның тест кезеңі 30 күндік бақылаудан тұрды. Осы айырмашылық нәтижелерді түсіндіру кезінде ескерілді.

Нәтижелер. 1-кестеде модельдердің тестілік кезеңдегі нәтижелері көрсетілген. Күн генерациясы бойынша ең төмен RMSE мәні терезелік прокси-модельде байқалды. XGBoost нәтижесі оған өте жақын болды. Жел генерациясында екі модельдің RMSE мәндері шамалас болды, бұл жел генерациясының кездейсоқ ауытқулары жоғары екенін көрсетеді.

Кесте 1. Модельдердің болжау нәтижелері [Table 1 – Model Forecasting Results]

Модель / Model	RMSE	MAE	MAPE (%)
ARIMA (күн/solar, daily)	130,23 MWh	104,60 MWh	11,4
XGBoost (күн/solar)	23,44 MW	18,35 MW	90,0*
XGBoost (жел/wind)	179,92 MW	144,82 MW	105,8*
Прокси-модель/Proху (күн/solar)	21,50 MW	16,42 MW	72,0*
Прокси-модель/Proху (жел/wind)	179,71 MW	139,88 MW	113,5*

* Ескерту: MAPE мәндері нөлге жақын генерация кезеңдерінде жоғары болуы мүмкін, сондықтан негізгі салыстыру RMSE және MAE бойынша жүргізілді.

Күн генерациясы бойынша: прокси-модель XGBoost-тан сәл жақсы нәтиже берді (21,50 vs 23,44 МВт RMSE). ARIMA тәуліктік жиынтық деректермен жұмыс істейді (МВт·сағ), сондықтан оның мәні сағаттық модельдермен тікелей салыстырылмайды — тек базалық бағдар ретінде қарастырылады.

Жел генерациясы бойынша: екі модельдің нәтижесі бірдей деңгейде (179,92 vs 179,71 МВт RMSE). Бұл жел генерациясының жоғары стохастикалық сипатын және тек тарихи деректерге сүйенудің шектеулілігін көрсетеді. Ауа райы айнымалыларын қосу болжам дәлдігін арттыруы мүмкін.

MAE абсолюттік орташа қатені өлшейді. Прокси-модель күн генерациясы үшін ең төмен MAE мәнін берді (16,42 МВт), бұл оның тәуліктік заңдылықтарды XGBoost-қа қарағанда сәл жақсы ұстайтынын көрсетеді.

MAPE нөлге жақын генерация кезеңдерінде (түнгі сағаттар, жел жоқ кездер) жоғары мән береді — бұл модельдің нашарлығын емес, метриканың шектеулілігін көрсетеді. ARIMA-ның 11,4% деп көрінетін нәтижесі оның тәуліктік деректермен жұмыс істеуінен туындайды. Негізгі салыстыру үшін RMSE және MAE қолданылуы ұсынылады.

Талқылау. Күн генерациясы бойынша алынған нәтижелер лагтық және терезелік белгілерді қолданатын модельдердің классикалық статистикалық тәсілдерге қарағанда тиімді болатынын көрсетті. Прокси-модель XGBoost-тан сәл жақсы нәтиже берді, бірақ айырмашылық өте үлкен емес. Бұл студенттік зерттеу үшін маңызды қорытынды: күрделі модель әрқашан айтарлықтай артықшылық бере бермейді, әсіресе деректер көлемі шектеулі болған жағдайда.

Жел генерациясын болжау күрделірек болды. XGBoost пен прокси-модельдің нәтижелері бір-біріне жақын болды. Бұл желдің кездейсоқ сипаты мен сыртқы метеорологиялық факторлардың маңызды екенін көрсетеді. Егер нақты ауа райы болжамдары, жел жылдамдығы, қысым және температура сияқты қосымша белгілер қолданылса, модельдердің сапасы жақсаруы мүмкін.

MAPE метрикасының жоғары мәндері модельдердің міндетті түрде нашар екенін білдірмейді. Күн генерациясы түнде нөлге жақын болады, ал жел генерациясы кейбір кезеңдерде өте төмен болуы мүмкін. Мұндай жағдайда аз абсолюттік қате де үлкен пайыздық қате ретінде көрінеді. Сондықтан жаңартылатын энергияны болжауда RMSE, MAE және нормаланған RMSE сияқты метрикаларды бірге қолдану қажет (Hong et al., 2016: 896).

Зерттеудің шектеулері. Бұл жұмыстың бірнеше шектеуі бар. Біріншіден, зерттеу нақты өндірістік деректерге емес, синтетикалық деректерге негізделді. Сондықтан нәтижелер нақты электр станциялары үшін тікелей қолдануға арналмаған. Екіншіден, толық LSTM нейрондық желісі емес, оның логикасын түсіндіретін жеңілдетілген прокси-модель қолданылды. Үшіншіден, ARIMA моделі күнделікті деректерге, ал XGBoost және прокси-модель сағаттық деректерге қолданылды. Осы себепті ARIMA нәтижелері тек базалық бағдар ретінде қарастырылды.

Болашақ зерттеулерде нақты ENTSO-E, Open Power System Data немесе Renewables.ninja деректерін пайдалану, сондай-ақ толық LSTM, GRU және LightGBM модельдерін қосу ұсынылады. Сонымен қатар ауа райы айнымалыларын енгізу модельдердің практикалық маңызын арттырады.

Қорытынды. Бұл мақалада жаңартылатын энергия генерациясын қысқа мерзімді болжау үшін ARIMA, XGBoost және LSTM логикасына ұқсас терезелік прокси-модель салыстырылды. Зерттеу синтетикалық сағаттық деректер негізінде орындалды және бакалавриат деңгейіндегі оқу-зерттеу жұмысы ретінде қарастырылды.

Нәтижелер күн генерациясы үшін прокси-модельдің ең төмен RMSE мәнін көрсеткенін (21,50 МВт), ал XGBoost моделінің оған жақын нәтиже бергенін (23,44 МВт) анықтады. Жел генерациясы үшін екі модельдің сапасы шамалас болды. Бұл жел генерациясын болжауда сыртқы метеорологиялық факторлардың маңызын көрсетеді.

Жалпы алғанда, жұмыс машиналық оқыту модельдерінің жаңартылатын энергияны болжау міндеттерінде пайдалы екенін көрсетті. Сонымен бірге зерттеу MAPE метрикасын абайлап қолдану қажет екенін және нақты деректермен жұмыс істеу болашақ зерттеулер үшін маңызды бағыт екенін дәлелдеді.

Қосымша: Python кодына қысқаша сипаттама. Зерттеуде Python тіліндегі numpy, pandas, statsmodels, xgboost және scikit-learn кітапханалары қолданылды. Кодтың негізгі кезеңдері: синтетикалық деректерді генерациялау, уақыт бойынша train/test бөлу, лагтық белгілерді құру, XGBoost моделін оқыту, терезелік прокси-модельді құру және RMSE, MAE, MAPE метрикаларын есептеу.

Деректер көздері.

- Renewables.ninja — hourly solar and wind capacity factors, CSV format.
- ENTSO-E Transparency Platform — actual generation data by production type, hourly resolution.
- Open Power System Data — cleaned European power-system time series.
- EIA Open Data — electricity generation data for the United States.

Әдебиеттер

- Antonanzas, J., Osorio, N., Escobar, R., Urraca, R., Martinez-de-Pison, F. J., Antonanzas-Torres, F. (2016). Review of photovoltaic power forecasting. *Solar Energy*, 136, 78–111. <https://doi.org/10.1016/j.solener.2016.06.069>
- Bacher, P., Madsen, H., Nielsen, H. A. (2009). Online short-term solar power forecasting. *Solar Energy*, 83(10), 1772–1783. <https://doi.org/10.1016/j.solener.2009.05.016>
- Chen, T., Guestrin, C. (2016). XGBoost: A scalable tree boosting system. *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, 785–794. <https://doi.org/10.1145/2939672.2939785>
- Hochreiter, S., Schmidhuber, J. (1997). Long short-term memory. *Neural Computation*, 9(8), 1735–1780. <https://doi.org/10.1162/neco.1997.9.8.1735>
- Hong, T., Pinson, P., Fan, S. (2016). Global Energy Forecasting Competition 2014: Probabilistic energy forecasting. *International Journal of Forecasting*, 32(3), 896–913. <https://doi.org/10.1016/j.ijforecast.2016.02.001>
- Hyndman, R. J., Athanasopoulos, G. (2021). *Forecasting: Principles and Practice*. 3rd ed. OTexts.
- Jung, J., Broadwater, R. P. (2014). Current status and future advances for wind speed and power forecasting. *Renewable and Sustainable Energy Reviews*, 31, 762–777. <https://doi.org/10.1016/j.rser.2013.12.054>
- Lago, J., Marcjasz, G., De Schutter, B., Weron, R. (2021). Forecasting day-ahead electricity prices: A review of state-of-the-art algorithms, best practices and an open-access benchmark. *Applied Energy*, 293, 116983. <https://doi.org/10.1016/j.apenergy.2021.116983>
- Lim, B., Arik, S. O., Loeff, N., Pfister, T. (2021). Temporal Fusion Transformers for interpretable multi-horizon time series forecasting. *International Journal of Forecasting*, 37(4), 1748–1764. <https://doi.org/10.1016/j.ijforecast.2021.03.012>
- Pfenninger, S., Staffell, I. (2016). Long-term patterns of European PV output using 30 years of validated hourly reanalysis and satellite data. *Energy*, 114, 1251–1265. <https://doi.org/10.1016/j.energy.2016.08.060>
- Qing, X., Niu, Y. (2018). Hourly day-ahead solar irradiance prediction using weather forecasts by LSTM. *Energy*, 148, 461–468. <https://doi.org/10.1016/j.energy.2018.01.177>
- Sabri, S., Koohi-Kamali, S., Rahim, N. A. (2018). Solar photovoltaic generation forecasting methods: A review. *Energy Conversion and Management*, 156, 459–497. <https://doi.org/10.1016/j.enconman.2017.11.019>
- Staffell, I., Pfenninger, S. (2016). Using bias-corrected reanalysis to simulate current and future wind power output. *Energy*, 114, 1224–1239. <https://doi.org/10.1016/j.energy.2016.08.068>
- Voyant, C., Nottot, G., Kalogiros, S., Nivet, M. L., Paoli, C., Motte, F., Fouilloy, A. (2017). Machine learning methods for solar radiation forecasting: A review. *Renewable Energy*, 105, 569–582. <https://doi.org/10.1016/j.renene.2016.12.095>
- Zhou, H., Zhang, S., Peng, J., Zhang, S., Li, J., Xiong, H., Zhang, W. (2021). Informer: Beyond efficient transformer for long sequence time-series forecasting. *Proceedings of the AAAI Conference on Artificial Intelligence*, 35(12), 11106–11115.