



OPEN ACCESS

*CORRESPONDENCE

Tuvshin Osgonbaatar

E-mail address:

o.tuvshin.21@gmail.com

RECEIVED: November 16, 2023

ACCEPTED: December 25, 2023

PUBLISHED: December 29, 2023

CITATION

A. Rusina, T. Osgonbaatar, P. Matrenin, and Z. Bayasgalan, "Machine Learning Application for Renewable Energy Forecasting", Journal of Energy Transition, vol. 1, no. 1, pp. 13–22, Dec. 2023.

<https://doi.org/10.59264/jet.v1i1.29>

COPYRIGHT

©2023 by the authors. Submitted for possible open access publication under the terms and conditions of the Creative Commons Attribution (CC BY) license.

Machine Learning Application for Renewable Energy Forecasting

Anastasia G. Rusina¹, Tuvshin Osgonbaatar^{1*}, Pavel V. Matrenin², Zagdkhorol Bayasgalan³¹(Power Plants Department, Novosibirsk State Technical University, Novosibirsk, Russia)²(Power Supply System Department, Novosibirsk State Technical University, Novosibirsk, Russia)³(School of Power Engineering, Mongolian University of Science and Technology, Ulaanbaatar, Mongolia)

Abstract - Renewable energy is a clean source known as green energy. Its benefits are enough established. However, its effective use and increasing its share have become a major challenge for system operators. Due to its direct dependence on environmental and meteorological factors, there are often uncertainties and unexpected consequences for integrated energy system planning. Thus, the prediction of the production of renewable sources is a very relevant issue. This paper considers the application of ensemble machine learning models for renewable energy forecasting. As input data for the machine learning model, historical data on power generation was used for the 2019–2021 period of renewable energy including meteorological data from the power plants operating in the central power system of Mongolia. The ensemble machine learning model allows us to determine the non-linear and non-stationary dependence of the time series and can be implemented in the task of forecasting the daily generation schedule. The proposed model creates a day-ahead forecast of the hourly generation curve of the photo-voltaic power plants under consideration with a normalized absolute percentage error of 6.5 – 8.4%, and for wind farms, 12.3-13.3%. Increasing the accuracy of renewable energy forecasting can positively affect the operation and planning of the central power system of Mongolia.

Key words - Forecasting, Ensemble machine learning, Photovoltaic power plant, Wind farm.

Сэргээгдэх эрчим хүчний таацад машин сургалт ашиглах нь

А.Г. Русина¹, Огсонбаатарын Түвшин^{1*}, П.В. Матренин², Баясгалангийн Загдхорол³¹(Цахилгаан станцын тэнхим, Новосибирскийн Техникийн Их Сургууль, Новосибирск, ОХУ)²(Цахилгаан хангамжийн тэнхим, Новосибирскийн Техникийн Их Сургууль, Новосибирск, ОХУ)³(Эрчим Хүчний Сургууль, Шинжлэх Ухаан Технологийн Их Сургууль, Улаанбаатар, Монгол)

Хураангуй - Сэргээгдэх эрчим хүч нь ногоон эрчим хүч хэмээн нэрлэгдэх цэвэр эх үүсвэр бөгөөд түүний давуу талууд хангалттай нотлогдсон. Гэвч зөв зохистой ашиглах, эзлэх хувь хэмжээг нэмэгдүүлэх нь системийн операторуудад томоохон сорилт болж байна. Тодруулбал, байгаль, цаг уурын хүчин зүйлсээс шууд хамааралтай тул нэгдсэн эрчим хүчний системийн төлөвлөлтөнд тодорхойгүй байдал, гэнэтийн нөлөөлөл үзүүлэх нь элбэг. Иймд сэргээгдэх эх үүсвэрүүдийн үйлдвэрлэлийн таацыг оновчтой зөв гүйцэтгэх нь нэн шаардлагатай асуудал юм. Энэхүү судалгааны ажлын зорилго нь нар, салхины эх үүсвэрүүдийн өдөр тутмын үйлдвэрлэлийн графикийг урьдчилан таамаглах аргачлалыг боловсруулахад оршино. Төвийн бүсийн нэгдсэн сүлжээнд зэрэгцээ ажиллаж буй сэргээгдэх эрчим хүчний эх үүсвэрүүдийн 2019-2021 оны үйлдвэрлэл болон цаг уурын өгөгдлүүдийг уг судалгаанд ашигласан болно. Машин сургалтын алгоритмууд, тэр дундаа олонлог-загварчлалууд нь олон тооны хувьсагчдын шугаман бус, стохастик хамаарлыг тодорхойлох чадвартай тул уг даалгаварт илүү тохиромжтой шийдэл болно. Нийтлэлд санал болгож буй аргачлал нь нарны цахилгаан станцуудын хувьд 6,5-8,4 %, салхин цахилгаан станцуудын хувьд 12,3-13,3 % нарийвчлалтай таац гүйцэтгэсэн. Иймд машин сургалтын алгоритм ашиглан сэргээгдэх эрчим хүчний богино хугацааны таацыг хийж гүйцэтгэх нь эрчим хүчний системийн үйл ажиллагаа, богино хугацааны төлөвлөлтөнд эерэг нөлөө үзүүлэх болно.

Түлхүүр үг - Таац, Машин сургалт, Нарны цахилгаан станц, Салхин цахилгаан станц.

I. ОРШИЛ

Хатуу түлшний хэт их хэрэглээтэй холбоотой орчны бохирдол, уур амьсгалын өөрчлөлт, дэлхийн дулаарал, түлшний хомсдол зэрэг хүчин зүйлс нь уламжлалт эх үүсвэрээс татгалзах, шинэ алтернатив эх үүсвэрүүдийг хайх, ашиглах шалтгаан болж байна. Тогтмол хэвлэл, эрдэм шинжилгээний бүтээлүүд, судалгааны ажлуудад сэргээгдэх эрчим хүчний (СЭХ) эх үүсвэрүүдийн байгальд ээлтэй, ашиглалтын зардал бага зэрэг давуу талууд хангалттай нотлогдсон байдаг. Нар, салхины эрчим хүч нь СЭХ-ний гол нөөц болж, цахилгаан эрчим хүчний зах зээлд эзлэх хувь хэмжээ дэлхий даяар хурдацтай өсөж байна. Ойрын ирээдүйд, ялангуяа хөгжиж буй орнуудын цахилгаан эрчим хүний үйлдвэрлэлд голлох үүрэг гүйцэтгэх төлөвтэй байна.

СЭХ-ний өсөн нэмэгдэж буй үйлдвэрлэл (интеграцлал) нь техник-эдийн засгийн шинэ сорилтуудыг бий болгож, тэдгээрийн оновчтой шийдлүүдийг тасралтгүй шаарддаг. Тодруулбал, Эрчим хүчний системийн (ЭХС) нэгдсэн горим төлөвлөлт, зах зээл-арилжааны зохицуулалт хийхэд СЭХ-тэй холбоотой тодорхой асуудлууд тулгардаг [1,2]. Ялангуяа ЭХС-ийн хэрэглээ үйлдвэрлэлийг тасралтгүй тэнцвэржүүлэх, хэвийн найдвартай, үр ашигтай ажиллагааг хангахад СЭХ-ний оролцоог урьдчилан тодорхойлох нь голлох шийдлүүдийн нэг юм [3]. Уг судалгааны ажлын зорилго нь СЭХ-ний үйлдвэрлэлийн богино хугацааны таацыг гүйцэтгэх аргачлалыг санал болгоход чиглэнэ.

СЭХ-ний үйлдвэрлэл нь байгаль, цаг уур, орчны нөлөөллөөс шууд хамаарна [4,5]. Урьдчилан таамаглах асуудалд эдгээр санамсаргүй (стохастик) бөгөөд эмх замбараагүй (хаотистик) байгалийн хүчин зүйлс буюу шугаман болон шугаман бус олон тооны хувьсагчдыг авч үзэх нь зайлшгүй ба ихээхэн хүндрэлтэй [6]. Хэд хэдэн судалгааны ажлуудад [1,7-13] урьдчилан таамаглах асуудал болон физик, статистик болон хосолмол аргачлалын талаар авч үзсэн байдаг.

Физик аргачлал нь цаг уур, орчны өгөгдлүүдэд дүн шинжилгээ хийх замаар таац хийдэг бөгөөд үйлдвэрлэлийн статистик өгөгдлүүдийг шаардахгүй. Энэ аргачлал нь урт хугацаанд буюу СЭХ-ний төсөл хөгжүүлэлтэд ашиглагддаг [12]. Хэрэв үйлдвэрлэлийн цаг хугацааны цуврал бүхий тоон мэдээ хангалттай байгаа тохиолдолд уг өгөгдөлд боловсруулалт хийх замаар статистик аргачлал ашиглах нь илүү хялбар. Статистик аргачлалын давуу тал нь цаг уур, гадны нөлөөллийн физик өгөгдөл шаардахгүй [14]. Богино хугацааны таац хийх статистик аргачлалуудад бүх төрлийн авторегрессийн загварууд (ARIMA, ARMA, SARIMA) багтана [15,16].

Физик болон статистик аргачлалуудыг нэгтгэсэн хосолмол аргачлалыг машин сургалтын тусламжтайгаар боловсруулж болно [17]. Ийм төрлийн аргачлалуудад Neural Network [18,19], тулгуур вектор (Support Vector Machine) [3,20], фаззи логик (Fuzzy Logic) [8,21,22] зэрэг машин сургалтын алгоритмуудад суурилсан аргууд

багтана. Үүнээс гадна олонлог-загварчлал (Ensemble Learning Models) буюу хэд хэдэн регрессоруудын нэгдэл нь СЭХ-ний богино хугацааны таац гүйцэтгэхэд ашиглагдаж байна [2,3,29].

Нарны цахилгаан станцын хоногийн үйлдвэрлэлийн графикайн таац хийхэд авторегрессийн аргачлал хэрэглэхийг [23-27] судалгааны ажилд санал болгож, Neural Network-ийн үр дүнтэй харьцуулсан байдаг. Дээрх ажлуудад машин сургалт болон статистик аргачлалын онцлог, ялгааг тодорхой харуулсан байдаг. Мөн [28]-д 20 МВт хүчин чадал бүхий нарны цахилгаан станцын өдрийн өмнөх таацыг гүйцэтгэсэн. Санал болгож буй аргачлал нь тулгуур векторын тусламжтайгаар цаг уурын нөхцөлийг цэлмэг, үүлтэй, хур тунадас болон манан бүхий гэсэн ангиллаар загварчлах ба цаг агаарын мэдээний дагуу хоногийн ачааллыг тодорхойлсон. Салхины эрчим хүчний богино хугацааны таац хийхэд олонлог-загварчлалууд илүү үр дүнтэй болох нь дараах ажлуудаас харагддаг. Жишээ нь [30] салхины хурдыг дасан зохицох алгоритмын (Adaptive Boosting) тусламжтайгаар урьдчилан тооцоолсон ба тулгуур векторын тусламжтай үйлдвэрлэлийн графикт хувиргасан байдаг. Уг аргачлалыг 7 өөр салхин цахилгаан станц дээр туршсан бөгөөд хангалттай үр дүнг өгсөн. Үүнтэй ижил, [31-35] судалгааны ажлуудад дээрх загварчлалын хэд хэдэн алгоритмуудыг санал болгож, харьцуулсан үр дүнг тусгажээ.

Дээрх судалгааны ажлуудаас товч дүгнэвэл зөвхөн хоёр хувьсагчийн шугаман хамаарлыг загварчилдаг, бусад шугаман бус хамаарлыг тогтоох боломжгүй нь статистик аргуудын дутагдалтай тал нь юм. Регрессийн шинжилгээ, статистик аргуудын энэ дутагдлыг шийдвэрлэх, бусад цаг уур, орчны шугаман бус нөлөөллийг зэрэг тооцоолоход машин сургалтын алгоритмууд, тухайлбал олонлог-загварчлалыг өргөнөөр ашиглаж байна.

Энэхүү судалгааны ажилд олонлог-загварчлалын үндсэн төрлүүд болох санамсаргүй ой (Random Forest) [36,37], дасан зохицох чадвар нэмэх (Adaptive Boosting) [38], градиент нэмэх (XGBoost) [39,40] зэрэг алгоритмууд дээр суурилсан аргачлалуудыг СЭХ-ний богино хугацааны таац хийхэд санал болгоно. Анхны өгөгдлөөр 2019-2021 онуудын төвийн бүсийн нэгдсэн сүлжээнд (ТБНС) ажиллаж буй 6 нарны цахилгаан станц (НЦС), 3 салхин цахилгаан станцын (СЦС) үйлдвэрлэлийн цагийн мэдээ болон цаг уурын өгөгдлийг [41] ашигласан болно.


Судалгааны ажил нь дараах бүтэцтэй байна: II бүлэгт судалгааны аргачлалууд, тэдгээрийн математик загварчлалыг тайлбарласан болно. III бүлэгт тооцоололд ашигласан өгөгдлүүд, гарсан үр дүнг агуулсан болно. Эцэст нь IV бүлэгт судалгааны ажлыг дүгнэнэ.

II. СУДАЛГААНЫ АРГАЧЛАЛ

A. Шийдвэрийн Мод (Decision Tree)

Шийдвэрийн мод [42] нь шаталсан бүтэц бүхий зангилаа болон салаануудын багц юм. Зангилаа бүрд

нэгэн төрлийн оролтын хувьсагч болон гаралт хооронд регрессийн шинжилгээ эсвэл ангилал хийгдэх ба шийдвэр буюу үр дүн нь салаануудаар дамжин дараагийн зангилаанд шилжинэ. Төгсгөлийн зангилаа нь ангилал эсвэл регрессийн шинжилгээний үр дүнг өгдөг. Зураг 1-т шийдвэрийн модны бүтцийг харуулав.



Зураг 1. Шийдвэрийн мод

Уг судалгааны ажилд цаашид шийдвэрийн модыг регрессор гэж ойлгоно. Регрессорын нарийвчлал нь модны гүнээс (max_depth) хамаарна. Модны гүн их байх тусам, нарийвчлал өндөр байна. Нөгөөтээгүүр, алгоритмын ажиллах хугацаа их болно.

Илэрхийлэлд (1) өгсөн цаг хугацааны цувааг авч үзье. Аль нэг X_n оролтын хувьсагчийн хувьд регрессийн шинжилгээ хийж гаралтын функц буюу загварыг (2) өгнө.

$$S_n = \{(X_1, Y_1), (X_2, Y_2), \dots, (X_n, Y_n)\} \quad (1)$$


$X - f(X)$ функц бүхий оролтын хувьсагч; $Y -$ гаралтын хувьсагч; $S_n - n$ хэмжээний хувьсагч бүхий цаг хугацааны цуваа.

$$\hat{h}(X, S_n) \quad (2)$$

$\hat{h}(X, S_n) - n$ дугаар оролтын хувьсагч болон гаралтын утгын хамаарлын функц буюу загвар.

В. Олонлог-загварчлал (Ensemble Model)

Хэд хэдэн шийдвэрийн мод буюу регрессоруудын нэгдэл нь хүчтэй таамаглагч буюу олонлог-загварчлалыг үүсгэдэг. Өөрөөр хэлбэл загварчилж буй цаг хугацааны цувралын бүх гадна болон дотоод нөлөөллийг нэгэн зэрэг тооцоолж, олон хүчин зүйлт загварыг бий болгодог. Өөр өөр шинж чанар бүхий оролтын хувьсагчдын комбинацын тоогоор олонлог-загварчлал дахь регрессоруудын тоог (n_estimators) тодорхойлно. Оролтын хувьсагч бүрийг ашиглах нь алгоритмын ажиллах хугацааг нэмэгдүүлэх тул тодорхой тооны хамаарал өндөр хувьсагчдыг ашиглахыг зөвлөдөг. Иймд модны гүн (max_depth) болон тоог (n_estimators) оновчтой хэмжээгээр сонгох шаардлагатай. Үүнээс гадна загварыг бүтээхэд регрессоруудыг багцлах (bagging) эсвэл эрс нэмэгдүүлэх (boosting) гэсэн үндсэн хоёр техникийг ашигладаг. Зураг 2-т олонлог-загварчлалын бүтцийг харуулав.



Зураг 2. Олонлог - загвар

Санамсаргүйн ойн алгоритм [36] нь шийдвэрийн модны зарчим дээр суурилсан олонлог-загваруудын нэг төлөөлөл юм. Үндсэн зарчим нь S_n хугацааны цувралын n тооны оролтын хувьсагчидыг багцалж санамсаргүй байдлаар шийдвэрийн мод тус бүр дээр байрлуулна. Шийдвэрийн мод бүр регрессийн шинжилгээ хийж тус тусын үр дүнг (2) өгнө. Регрессоруудын үр дүнг дундажлах замаар санамсаргүй ойн алгоритмын загвар функцийг боловсруулна.

$$Y' = \frac{1}{N} \sum_{n=1}^N \hat{h}(X, S_n) \quad (3)$$

$Y' - n$ оролтын хувьсагч бүхий санамсаргүй ойн алгоритмын загвар.

Энэ тохиолдолд хувьсагч бүр тэгш оролцоотой ба ач холбогдол, хамаарал бага хувьсагчид загварын үр дүнд сөрөг нөлөө үзүүлэх нь бий. Иймд загварын нарийвчлал, үр дүнг сайжруулах зорилгоор регрессор бүрийг өөр хоорондоо харилцан хамааралтайгаар байгуулах буюу хэт нэмэгдүүлэх чиг хандлагыг ашигладаг. Өөрөөр хэлбэл харилцан хамаарал өндөр хувьсагчдын оролцоог нэмэх буюу бустлэх, үл хамаарах хувьсагчдыг шийдвэрт бага оролцуулах зорилготой.

Дасан зохицох чадвар нэмэх [38] алгоритм нь итерацийн процессын тусламжтайгаар регрессор бүрийг байгуулна. Энэхүү алгоритмд регрессорын гаралт бүрийг өмнөх давталтын алдааг харгалзан тооцсон коэффициентээр жинлэнэ.

$$Y'' = \frac{1}{N} \sum_{n=1}^N a_n * \hat{h}(X, S_n) \quad (3)$$

$Y'' - n$ оролтын хувьсагч бүхий дасан зохицох алгоритмын загвар, $a_n - n$ дугаар оролтын хувьсагчийн оролцооны коэффициент.

Ингэснээр алдаа өндөр регрессоруудын гаралт бага, алдаа бага регрессорууд гаралт өндөр оролцоотой болно.

Градиент нэмэх алгоритм [40] – градиент уналтын зарчим, итерацийн процесс дээр үндэслэгдсэн загварчлал юм. Давталт бүрт урьдчилан таамагласан болон бодит утгын хоорондох алдааг тооцоолдог ба градиент уналтын

зарчимаар алдааг бууруулах замаар регрессоруудыг байгуулдаг.

$$Y''' = \sum_{n=1}^n L(y, \hat{h}_{n-1}(X)) + \hat{h}_n(X) \quad (4)$$

Y''' – n оролтын хувьсагч бүхий градиент нэмэх алгоритмын загвар, $L(y, \hat{h}_{n-1}(X))$ – $n - 1$ дугаар регрессорын алдааны функц, $\hat{h}_n(X)$ – n дугаар регрессорын загвар функц.

III. ҮР ДҮН

Анхны өгөгдлөөр 2019-2021 онуудын ТБНС-нд зэрэгцээ ажиллаж буй 6 НЦС, 3 СЦС-ын үйлдвэрлэлийн цагийн мэдээ болон цаг уурын өгөгдлийг ашигласан болно. Оролтын өгөгдлийг машин сургалтын алгоритмыг сургах болон туршихад зориулж 70 %, 30 % харьцаатай багцад ангилсан.


A. Нарны Цахилгаан Станцын Таац Хийх

НЦС-ын үйлдвэрлэл нь нарны цацраг буюу радиациар тодорхойлогддог боловч түүнд үүлний өндөр, төрөл, салхины хурд зэрэг стохастик бүрэлдэхүүн хэсгүүд шууд нөлөөлөх тул цаг агаарын урьдчилсан мэдээнд тэр бүр өргөн тусгагддаггүй. Иймд алгоритмын оролтын өгөгдлөөр нарны цацраг буюу радиацийг шууд авч үзэх боломжгүй. Харин тухайн НЦС-ын ойрын өнгөрсөн өдрүүдийн үйлдвэрлэлийн мэдээгээр (gen-i) цацрагийн шинж чанарыг төлөөлүүлэн авч үзэх боломжтой. Мөн Нарны цацраг, тусгалын өнцөг нь улирлаас хамаарч өөр өөр байдаг тул урьдчилан таамаглах ажилд хуанлийн онцлогийг (month, day, hour) харгалзан үзэх шаардлагатай [2]. Санамсаргүй бүрэлдэхүүн хэсгүүдийн хувьд үүлэрхэг байдал (cloud_cover), хур тунадас (precipitation), агаарын температур (temp) зэрэг мэдээллийг авч үзнэ. Хүснэгт 1-т дээрх хувьсагчдыг харуулав.


Хүснэгт 1. Оролт болон гаралтын хувьсагчид

Хувьсагчдын төрөл	Хувьсагчид			
hour	00	01	...	23
gen-3	X_1	X_2	...	X_{24}
gen-2	X_{25}	X_{26}	...	X_{48}
gen-1	X_{49}	X_{50}	...	X_{72}
precipitation	X_{73}	X_{74}	...	X_{96}
temp	X_{97}	X_{98}	...	X_{120}
cloud_cover	X_{121}	X_{122}	...	X_{144}
month		X'_1		
day		X'_2		
hour		X'_3		
forecast	Y_1	Y_2	...	Y_{24}

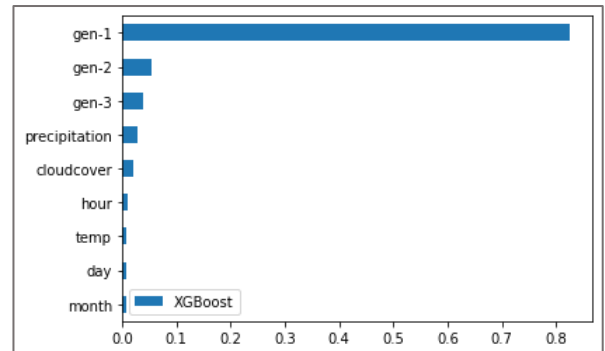
Зураг 3-5-т НЦС-ын хоногийн өмнөх үйлдвэрлэлийг урьдчилан таамаглах загварыг бий болгоход дээрх хувьсагчдын оролцоог харуулав. Мөн Хүснэгт 2-т туршилтын багцын нарийвчлалыг загвар тус бүрээр харуулав.



Зураг 3. Санамсаргүй ойн загварт хувьсагчдын оролцох оролцоо



Зураг 4. Дасан зохицох загварт хувьсагчдын оролцох оролцоо




Зураг 5. Градиент нэмэх загварт хувьсагчдын оролцох оролцоо


Хүснэгт 2. Загварын нарийвчлалын үнэлгээ

Загвар	Алдаа	Нарны цахилгаан станцын дугаар						Дүн
		1	2	3	4	5	6	
RF	MAE, MBт	0,32	0,39	0,56	0,27	0,84	0,52	0,48
	nMAE, %	17,7	18,1	17,5	12,4	15,6	18,6	16,7
AD	MAE, MBт	0,19	0,23	0,32	0,16	0,41	0,29	0,26
	nMAE, %	10,7	10,4	9,90	7,40	7,60	10,5	9,40
XB	MAE, MBт	0,17	0,20	0,29	0,14	0,38	0,26	0,24
	nMAE, %	9,50	9,30	9,10	6,20	7,60	9,30	8,50


Туршилтын багцын үр дүнгээс харахад градиент нэмэх (XGBoost), дасан зохицох чадвар нэмэх (Ada Boost) загварууд нь илүү нарийвчлалтай байна. Энэ нь эдгээр алгоритмууд нь загварыг бүтээхэд өмнөх алдааг тооцох, түүнийг багасгах чадвартай нь холбоотой юм. Жишээ болгон Гэгээн НЦС-н загварын туршилтын багцын бодит болон таамагласан муруйн хэсгийг Зураг 6-8-д харуулав.



Зураг 6. Санамсаргүй ойн загварын туршилтын багц

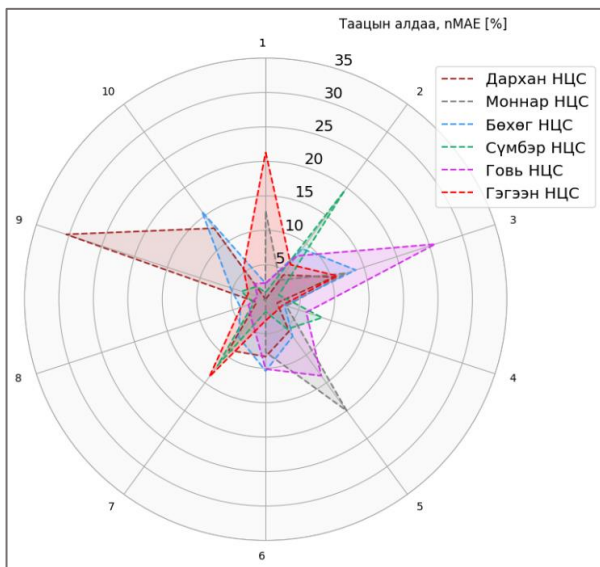


Зураг 7. Дасан зохицох чадвар нэмэх загварын туршилтын багц



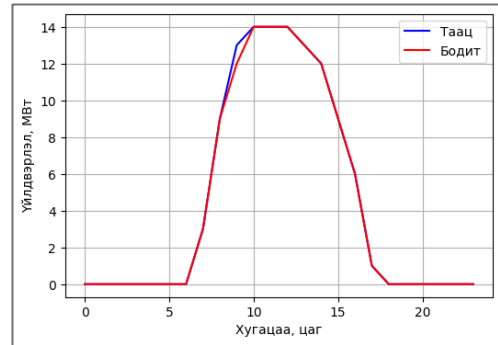
Зураг 8. Градиент нэмэх загварын туршилтын багц

ТБНС-нд зэрэгцээ ажиллаж буй НЦС-уудын хоногийн үйлдвэрлэлийн графикийг дасан зохицох чадвар нэмэх загвараар урьдчилан таац хийв. Санамсаргүй байдлаар сонгосон бодит хоногийн үйлдвэрлэлийн 10 график дээр туршилт хийсэн [43]. Зураг 9-д хоногийн дээрх таацын үр дүнг НЦС тус бүрээр харуулж байна.




Зураг 9. НЦС-уудын хоногийн үйлдвэрлэлийн таацын алдаа

Мөн жишээ болгон Зураг 10-т Гэгээн НЦС-ын, Зураг 11-д Бөхөг НЦС-ын хоногийн үйлдвэрлэлийн графикийг харуулав.



Зураг 10. Гэгээн НЦС-ын хоногийн үйлдвэрлэлийн таац




Зураг 11. Бөхөг НЦС-ын хоногийн үйлдвэрлэлийн таац


В. Салхин Цахилгаан Станцын Таац

СЦС-ын хоногийн үйлдвэрлэлийн таацыг гүйцэтгэхэд салхины хурдыг оновчтой загварчлах шаардлагатай. Салхины хурд нь эмх замбараагүй хоастик шинж чанартай тул түүнд нөлөөлж буй хувьсагчдыг тодорхойлох нь боломжгүй. Иймд алгоритмыг сургахад өмнөх долоо хоногийн цаг тутмын салхины хурд (*wind-i*) болон хуанлийн онцлог буюу сар (*month*), өдөр (*day*) зэрэг улирлын шинж чанартай мэдээллийг ашиглахыг санал болгож байна. Энэ нь аль сар, улирал болон хоногийн аль үед салхины хүч ямар байх талаар тооцох боломжийг олгоно.

Зураг 12-т дээрх хувьсагчдын салхины хурдыг санамсаргүй ойн алгоритмаар таацлахад нөлөөлөх нөлөөг үзүүлэв. Мөн Хүснэгт. 3-д дээр дурдсан загваруудын нарийвчлалын үнэлгээг харуулав.



Зураг 12. Салхины хурдны таац хийхэд хувьсагчдын оролцох оролцоо



Зураг 16. Салхин турбины чадлын муруй

Хүснэгт 3. Загварын нарийвчилсан үнэлгээ


Загвар	Алдаа	Салхин цахилгаан станцын дугаар			
		1	2	3	Дүн
RF	MAE, м/с	2,03	2,14	2,21	2,12
	nMAE, %	24,16	26,70	27,23	26,03
AD	MAE, м/с	1,52	1,70	1,74	1,62
	nMAE, %	18,06	21,13	21,37	20,18
XB	MAE, м/с	1,05	1,09	1,12	1,08
	nMAE, %	12,55	13,60	13,74	13,29

Салхин турбины чадлын муруй нь ажиллаж эхлэх хурд V_{cut-in} , дээд ажиллах хурд V_{rate} болон критик буюу таслах хурд $V_{cut-out}$ гэсэн үндсэн цэгүүдтэй. Эдгээр цэгүүд нь графикийг 4 хэсэгт хуваах ба хэсэг бүрд чадал ба хурд өөр өөр хамааралтай байна. Хэрэв салхины хурд V ажиллаж эхлэх хурдаас V_{cut-in} бага эсвэл критик $V_{cut-out}$ хурдаас хэтрэх үед үйлдвэрлэл хийхгүй. Салхины хурд V нь $V_{rate} < V < V_{cut-out}$ үед салхин турбин хэвийн чадлаар ажиллна. Харин $V_{cut-in} < V < V_{rate}$ тохиолдолд турбины чадал дараах хамаарлаар тодорхойлогдоно.


Зураг 13-15-т туршилтын багцын бодит болон таацалсан салхины хурдны муруйн хэсгийг харуулав.

$$P = \frac{1}{2} C_p \rho \pi R^2 V^3, \quad V_{cut-in} < V < V_{rate} \quad (5)$$


P – турбины чадал, C_p – турбины коэффициент, ρ – агаарын нягт, R – роторын радиус, V – салхины хурд.



Зураг 13. Санамсаргүй ойн загварын туршилтын багц



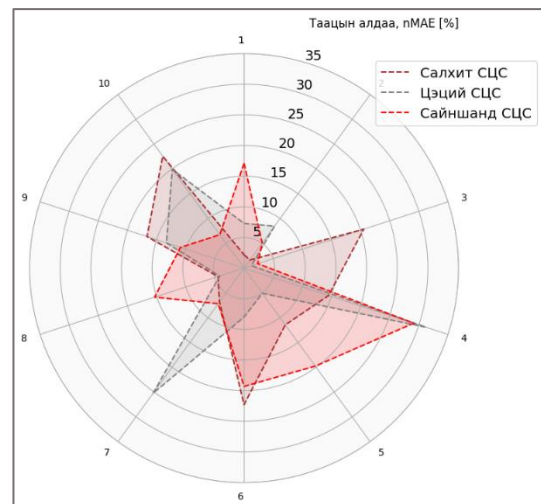
Зураг 14. Дасан зохицох чадвар нэмэх загварын туршилтын багц



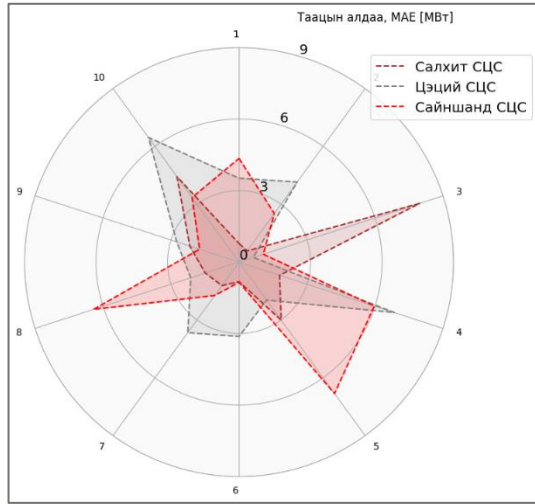
Зураг 15. Градиент нэмэх загварын туршилтын багц

ТБНС-нд зэрэгцээ ажиллаж буй СЦС-уудын хоногийн үйлдвэрлэлийн графикийг градиент нэмэх алгоритмын загвараар урьдчилан таац хийв. Санамсаргүй байдлаар сонгосон бодит хоногийн үйлдвэрлэлийн 10 график дээр туршилт хийсэн. Зураг. 17,18-д хоногийн өмнөх таацын үр дүнг харуулав.

Хүснэгт 3 болон Зураг 13-15-аас харахад градиент нэмэх алгоритмаар бүтээсэн загвар нь илүү нарийвчлал өндөр байна. Уг загвараар урьдчилан таамагласан салхины хурдны цувааг, чадалд хувиргах замаар СЦС-ын хоногийн үйлдвэрлэлийн таацыг гүйцэтгэсэн. Салхины хурд болон турбины чадлын хамаарлыг Зураг. 16-д харуулав. Уг хамаарал нь СЦС тус бүрд өөр өөр байдгийг тэмдэглэх нь зүйтэй.

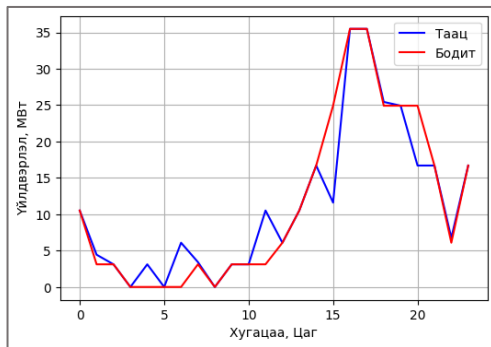


Зураг 17. СЦС-уудын хоногийн үйлдвэрлэлийн таацын алдаа, %

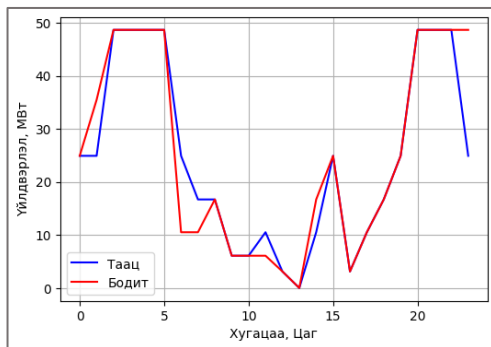


Зураг 18. СЦС-уудын хоногийн үйлдвэрлэлийн таацын алдаа, МВт

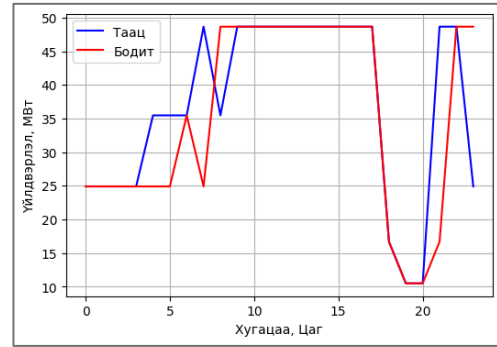
Мөн Зураг 19-21-д жишээ болгон СЦС-уудын нэг өдрийн үйлдвэрлэлийн графикуудыг үзүүлэв.



Зураг 19. Салхит СЦС-ын хоногийн үйлдвэрлэлийн график



Зураг 20. Цэций СЦС-ын хоногийн үйлдвэрлэлийн график



Зураг 21. Сainшанд СЦС-ын хоногийн үйлдвэрлэлийн график

IV. ДҮГНЭЛТ

Эрчим хүч үйлдвэрлэх, дамжуулах, түгээх бүхий л үе шатанд шинэ техник, технологи эрчимтэй нэвтэрч, уламжлалт бүтцээс шинэлэг элементүүд агуулсан бүтэц рүү эрчимтэй шилжиж байна. Сэргээгдэх эрчим хүчний өсөн нэмэгдэж буй хэрэглээ нь үүний тод жишээ юм. Иймд эрчим хүчний системийн үйл ажиллагааг удирдах, горим төлөвлөх аргачлалыг илүү боловсронгуй болгох шаардлагатай юм.

Сэргээгдэх эрчим хүч нь байгаль, цаг уурын нөлөөллөөс шууд хамаарах тул сонгодог аргачлалуудыг ашиглахад хүндрэлтэй, үр дүн бага гэдэг нь энэ чиглэлээр хийгдсэн судалгааны ажлуудаар батлагдсан. Иймд олон хүчин зүйлсийг тооцоолох, их хэмжээний өгөгдөлд дүн шинжилгээ хийх чадвартай машин сургалтын алгоритм дээр суурилсан аргачлалыг хэрэглэхийг санал болгодог. Уг ажилд олонлог-загварчлалын үндсэн төрлүүдийг ашиглахыг санал болгож байна.

Судалгааны ажлыг ТБНС-нд зэрэгцээ ажиллаж буй 6 НЦС болон 3 СЦС-ын үйлдвэрлэлийн болон цаг уурын бодит өгөгдөл дээр гүйцэтгэсэн. Загварчлалыг Python программчлалын хэл дээр хэрэгжүүлсэн ба дараах үр дүнг өгсөн. НЦС-ын хоногийн үйлдвэрлэлийн графикийг 0,15 – 0,25 МВт буюу 6,5 – 8,4 % ийн алдаатай, СЦС-ын хувьд 2,4 – 3,5 МВт буюу 12,3 – 13,3 % ийн алдаатай таац хийж чадсан.

Санал болгож буй машин сургалтын нэгэн аргачлал болох олонлог-загварчлалын алгоритмуудыг дээрх эх үүсвэрүүдийн өдөр тутмын үйлдвэрлэлийн графикийг урьдчилан таамаглахад ашиглаж болно гэж дүгнэж байна. Сэргээгдэх эрчим хүчний эх үүсвэрүүдийн таацыг сайжруулах, нарийвчлалыг нэмэгдүүлэх нь түүнийг ашиглах боломжийг нэмэгдүүлэхэд тодорхой үүрэг гүйцэтгэх болно.

ЗОХИОГЧДЫН ХУВЬ НЭМЭР

Бүх зохиогчид хувь нэмэр оруулсан болно. Судалгааны ажлын үзэл баримтлал, зөвлөмжид А.Р, Б.З; арга зүйд П.В, О.Т; программчлал, үр дүнг баталгаажуулалтад П.В, О.Т; эх хувь бэлтгэх, хянан засварлахад О.Т, Б.З. Бүр зохиогчид гар бичмэлийн

хувилбарыг уншиж, олон нийтэд хэвлэхэд зөвшөөрч байна.

ТАЛАРХАЛ

Судалгааны ажлыг хэвлүүлэхэд MCS Research Grant 202301 дугаарт грант олгон дэмжлэг үзүүлсэн MCS International ХХК-д гүн талархал илэрхийлж байна. Мөн Новосибирскийн Техникийн Их Сургуулийн Цахилгаан станц болон Цахилгаан хангамжийн тэнхим, ШУТИС-ийн ЭХС-ийн Цахилгаан Техникийн Салбар хамтран ажилласанд талархал илэрхийлье.

АШИГЛАСАН МАТЕРИАЛ

- R. Tawn and J. Browell, "A review of very short-term wind and solar power forecasting," *Renewable and Sustainable Energy Reviews*, vol. 153, pp. 111758, 2022, doi: 10.1016/j.rser.2021.111758
- A. Khalyasmaa et al., "Prediction of solar power generation based on random forest regressor model," in *Proc. 2019 IEEE International Multi-Conference on Engineering, Computer and Information Sciences (SIBIRCON)*, 2019, pp. 780-785, doi: 10.1109/SIBIRCON48586.2019.8958063
- L. Visser, T. AlSkaif, and W. Van Sark, "Operational day-ahead solar power forecasting for aggregated PV systems with a varying spatial distribution," *Renewable Energy*, vol. 183, pp. 267-282, 2022, doi: 10.1016/j.renene.2021.10.102
- Z. O. A. Olaofe, "5-day wind speed and power forecasts using a layer recurrent neural network (LRNN)," *Sustainable Energy Technologies and Assessments*, vol. 6, pp. 1-24, 2014, doi: 10.1016/j.seta.2013.12.001
- M. Santos and M. González, "Factors that influence the performance of wind farms," *Renewable Energy*, vol. 135, pp. 643-651, 2019, doi: 10.1016/j.renene.2018.12.033
- T. Ouyang, A. Kusiak, and Y. He, "Predictive model of yaw error in a wind turbine," *Energy*, vol. 123, pp. 119-130, 2017, doi: 10.1016/j.energy.2017.01.150
- M. Guermoui M et al., "A comprehensive review of hybrid models for solar radiation forecasting," *Journal of Cleaner Production*, vol. 258, pp. 120357, 2020, doi: 10.1016/j.jclepro.2020.120357
- H. T. Yang et al., "A weather-based hybrid method for 1-day ahead hourly forecasting of PV power output," *IEEE transactions on sustainable energy*, no. 3, vol. 5, pp. 917-926, 2014, doi: 10.1109/TSTE.2014.2313600
- P. Gupta and R. Singh, "PV power forecasting based on data-driven models: a review," *International Journal of Sustainable Engineering*, vol. 6(14), pp. 1733-1755, 2021, doi: 10.1080/19397038.2021.1986590
- L. Zhao, S. N. Muhammad, M. J. Hafiz, and N. A. Ahmed, "A review on proliferation of artificial intelligence in wind energy forecasting and instrumentation management," *Environmental Science and Pollution Research*, vol. 29, pp. 43690-43709, 2022, doi: 10.1007/s11356-022-19902-8
- V. Manusov, P. Matrenin, M. Nazarov, and S. Beryozkina, "Short-Term Prediction of the Wind Speed Based on a Learning Process Control Algorithm in Isolated Power Systems," *Sustainability*, vol. 2(15), pp. 1730, 2023, doi: 10.3390/su15021730
- Tiwari and Seemant, "Wind speed forecasting methods for wind energy generation," in *Proc. 2022 IEEE 1st International Conference on Informatics (ICI)*, 2022, pp. 143-147, doi: 10.1109/ICI53355.2022.9786880
- R. Meenal et al., "Weather forecasting for renewable energy system: a review," *Archives of Computational Methods in Engineering*, vol. 5(29), pp. 2875-2891, 2022, doi: 10.1007/s11831-021-09695-3
- C. Wang et al., "A new wind power prediction method based on chaotic theory and Bernstein Neural Network," *Energy*, vol. 117, pp. 259-271, 2016, doi: 10.1016/j.energy.2016.10.041
- Li, Xiaou, Juan Francisco Sabas, and Vicente Duarte Mendéz, "Wind energy forecasting using multiple ARIMA models," in *Proc. 2022 IEEE 18th International Conference on Automation Science and Engineering (CASE)*, pp. 2034-2039, 2022, doi: 10.1109/CASE49997.2022.9926516
- F. Marchesoni-Acland et al., "Analysis of ARMA solar forecasting models using ground measurements and satellite images," in *Proc. 2019 IEEE 46th Photovoltaic Specialists Conference (PVSC)*, 2019, pp. 2445-2451, doi: 10.1109/PVSC40753.2019.8980821
- A. Abdellatif et al., "Forecasting photovoltaic power generation with a stacking ensemble model," *Sustainability*, no. 17, vol. 14, pp. 11083, 2022, doi: 10.3390/su141711083
- A. P. Marugán et al., "A survey of artificial neural network in wind energy systems," *Applied energy*, pp. 1822-1836, 2018, doi: 10.1016/j.apenergy.2018.07.084
- S. Theocharides et al., "Day-ahead photovoltaic power production forecasting methodology based on machine learning and statistical post-processing," *Applied Energy*, vol. 268, pp. 115023, 2020, doi: 10.1016/j.apenergy.2020.115023
- Y. Zhang, and R. Li, "Short term wind energy prediction model based on data decomposition and optimized LSSVM," *Sustainable Energy Technologies and Assessments*, vol. 52, pp. 102025, 2022, doi: 10.1016/j.seta.2022.102025
- Khasanzoda, Nasrullo et al., "Regression model for predicting the speed of wind flows for energy needs based on fuzzy logic," *Renewable Energy*, vol. 191, pp. 723-731, 2022, doi: 10.1016/j.renene.2022.04.017
- A. E. Saleh et al. "A hybrid neuro-fuzzy power prediction system for wind energy generation," *International Journal of Electrical Power & Energy Systems*, vol. 74, pp. 384-395, 2016, doi: 10.1016/j.ijepes.2015.07.039
- D. A. Snegirev et al., "Day-ahead solar power plant forecasting accuracy improvement on the hourly basis," in *Proc. 2019 IEEE Conference of Russian Young Researchers in Electrical and Electronic Engineering (EIConRus)*, 2019, pp. 1088-1091, doi: 10.1109/EIConRus.2019.8657024
- X. G. Agoua, R. Girard and G. Kariniotakis, "Short-term spatio-temporal forecasting of photovoltaic power production," *IEEE Transactions on Sustainable Energy*, no. 2, vol. 9, pp. 538-546, 2017, doi: 10.1109/TSTE.2017.2747765
- E. G. Kim, M. S. Akhtar and O. B. Yang, "Designing solar power generation output forecasting methods using time series algorithms," *Electric Power Systems Research*, vol. 216, pp. 109073, 2023, doi: 10.1016/j.epr.2022.109073
- W. Yin W et al., "A novel non-iterative correction method for short-term photovoltaic power forecasting," *Renewable Energy*, vol. 159, pp. 23-32, 2020, doi: 10.1016/j.renene.2020.05.134
- H. Sharadga, S. Hajimirza and R. S. Balog, "Time series forecasting of solar power generation for large-scale photovoltaic plants," *Renewable Energy*, vol. 150, pp. 797-807, 2020, doi: 10.1016/j.renene.2019.12.131

28. J. Shi et al., "Forecasting power output of photovoltaic systems based on weather classification and support vector machines," *IEEE Transactions on Industry Applications*, vol. 3(48), pp. 1064-1069, 2012, doi: 10.1109/TIA.2012.2190816
29. L. Visser, T. AlSkaif and W. Van Sark, "Benchmark analysis of day-ahead solar power forecasting techniques using weather predictions," In Proc. 2019 IEEE 46th Photovoltaic Specialists Conference (PVSC), 2019, pp. 2111-2116, doi: 10.1109/PVSC40753.2019.8980899
30. S. Buhan, Y. Özkazanç and I. Çadırcı, "Wind pattern recognition and reference wind mast data correlations with NWP for improved wind-electric power forecasts," *IEEE Transactions on Industrial Informatics*, vol. 3(12), pp. 991-1004, 2016, doi: 10.1109/TII.2016.2543004
31. T. Peng T et.al., "Negative correlation learning-based RELM ensemble model integrated with OVMD for multi-step ahead wind speed forecasting," *Renewable Energy*, vol. 156, pp. 804-819, 2020, doi: 10.1016/j.renene.2020.03.168
32. Y. Li et.al., "Smart wind speed forecasting approach using various boosting algorithms, big multi-step forecasting strategy," *Renewable energy*, vol. 135, pp. 540-553, 2019, doi: 10.1016/j.renene.2018.12.035
33. L. Wang, Y. Guo and X. Li, "Wind speed prediction using measurements from neighboring locations and combining the extreme learning machine and the AdaBoost algorithm," *Energy Reports*, vol. 8, pp. 1508-1518, 2022, doi: 10.1016/j.egy.2021.12.062
34. A. T. Dosdoğru and A. B. İpek, "Hybrid boosting algorithms and artificial neural network for wind speed prediction," *International Journal of Hydrogen Energy*, no. 3, vol. 47, pp. 1449-1460, 2022, doi: 10.1016/j.ijhpes.2021.107365
35. O. Abedinia et.al., "A multi-level model for hybrid short term wind forecasting based on SVM, wavelet transform and feature selection," In Proc. 2022 IEEE International Conference on Environment and Electrical Engineering and 2022 IEEE Industrial and Commercial Power Systems Europe (EEEIC/I&CPS Europe), 2022, pp. 1-6, doi: 10.1109/EEEIC/ICPSEurope54979.2022.9854519
36. Breiman Leo, "Random forests," *Machine learning*, vol.45, pp. 5-32, 2001, doi: 10.1023/a:1010933404324
37. K. L. Jorgensen and H. R. Shaker, "Wind power forecasting using machine learning: State of the art, trends and challenges," In Proc. 2020 IEEE 8th International Conference on Smart Energy Grid Engineering (SEGE), 2020, pp. 44-50, doi: 10.1109/SEGE49949.2020.9181870
38. Y. Freund and R. E. Schapire, "A decision-theoretic generalization of on-line learning and an application to boosting," *Journal of computer and system sciences*, no. 1, vol. 55, pp. 119-139, 1997, doi: 10.1006/jcss.1997.1504
39. X. Guo et al., "Study on short-term photovoltaic power prediction model based on the Stacking ensemble learning," *Energy Reports*, vol. 6, pp. 1424-1431, 2020, doi: 10.1016/j.egy.2020.11.006
40. Q. T. Phan, Y. K. Wu and Q. D. Phan, "A hybrid wind power forecasting model with XGBoost, data preprocessing considering different NWPs," *Applied Sciences*, no. 3, vol. 11, pp. 1100, 2021, doi: 10.3390/app11031100
41. <https://open-meteo.com>
42. A. Lahouar and J. B. H. Slama, "Hour-ahead wind power forecast based on random forests," *Renewable energy*, vol. 109, pp. 529-541, 2017, doi: 10.1016/j.renene.2017.03.064
43. Anastasia G. Rusina, Tuvshin Osgonbaatar, Alina I. Stepanova and Pavel V. Matrenin, "Ensemble Machine Learning Model for Day Ahead Solar Power Forecasting for Mongolia Power System," In Proc. 2023 Belarusian-Ural-Siberian Smart Energy Conference (BUSSEC), 2023, pp. 84-87. doi: 10.1109/BUSSEC59406.2023.10296344

ЗОХИОГЧИД

Rusina Anastasia Georgievna



Doctor of Technical Sciences, Dean of the Faculty of Energy, Head of the Power Plants Department at Novosibirsk State Technical University (NSTU NETI). An Expert at the Russian Academy of Sciences, a full member of RNC CIGRE, a full member of IEEE, and a member of the organizing committee of 5 international conferences. In 2006, she has received PhD degree; in 2013 DSc degree. Her research work includes 188 scientific publications, 3 monographs, and 6 state registration certificates for software. Areas of interest: load forecasting, hydropower plant operation modes modeling, targeted power distribution, optimization of plant operation modes.

Osgonbaatar Tuvshin



PhD student in Novosibirsk State Technical University (NSTU NETI), Russian Federation. He has received the Bachelor of degree in Electrical engineering from Power Engineering School, Mongolian University of Science and Technology (MUST). in 2009, and Master of Electrical engineering in 2016. His research areas are forecasting processes in power systems, optimization of electrical system operation modes.

**Matrenin Pavel Viktorovich**

PhD in Computer Science, leading researcher at Ural Power Engineering Institute of Ural Federal University, associate professor at Power Supply System Department and senior researcher at the Research Laboratory for Analysis, Processing, and Presentation of Data of Novosibirsk State Technical University. A

Member of IEEE, and a member of the organizing committee of 3 international conferences supported by IEEE.

In 2014 he has received master's degree, in 2018 – PhD degree. His research work includes 130 scientific publications, 1 monograph, and more than 10 state registration certificates for software. Areas of interest: explainable artificial intelligence, safe machine learning, timeseries forecasting, computer vision, optimization and control of power systems.

**Bayasgalan Zagdkhorol**

PhD in Technical Science, Professor at the Department of Electrotechnique, Power Engineering School (PES), Mongolian University of Science and Technology (MUST). An Expert at the Mongolian National Council for Education Accreditation, a full member of IEEE, WSTEAM, and

MATIYR.

In 1996 she has received master's degree from PES, MUST, in 2004 – PhD degree from National Research University “Moscow Power Engineering Institute”. Areas of research: power system analysis, electricity market, modeling of power system regimes, optimization, smart grid, control and multidisciplinary research.