



Elektr uzatish liniyalaridagi xavflarni vaqt qatori asosida prognozlashning mashinaviy o'qitish algoritmi

Qodirova Laylo Sobir qizi

O'zbekiston Milliy universiteti Jizzax filiali,
Kompyuter ilmlari va dasturlashtirish kafedrası
E-mail: layloqodirova208@gmail.com

ANNOTATSIYA

Maqolada elektr uzatish liniyalarida xavfli holatlarning o'zini aniqlashdan ko'ra, ularni yuz berishidan oldin prognozlashga yo'naltirilgan vaqt qatori modeli taklif etiladi. 5 daqiqalik diskretlash bilan 30 kunlik 8640 ta kuzatuvdan iborat fizik jihatdan asoslangan sintetik telemetriya to'plami shakllantirildi. Kuchlanish, tok, harorat, chastota, quvvat koeffitsiyenti va aktiv quvvatning kechikishlari, sirpanma o'rtachalari, dispersiyalari va trend ko'rsatkichlari hisoblandi. Logistik regressiya, Random Forest va Gradient Boosting taqqoslandi. 30 daqiqalik oldindan ogohlantirish uchun 0,4 LR + 0,6 RF gibrad modeli 0,8895 F1 va 0,9888 ROC-AUC berdi. Test davridagi 21 ta hodisaning barchasi 15–25 daqiqa oldin signal bilan qamrab olindi.

Kalit so'zlar:

elektr uzatish liniyasi, vaqt qatori, xavfni prognozlash, Random Forest, logistik regressiya, Gradient Boosting, SCADA, oldindan ogohlantirish, mashinaviy o'qitish.

Алгоритм машинного обучения для прогнозирования опасностей в линиях электропередач на основе временного ряда

АННОТАЦИЯ

В статье предлагается модель временного ряда, ориентированная на прогнозирование опасных состояний в линиях электропередачи до возникновения события, а не на его последующее обнаружение. Сформирован физически обоснованный синтетический набор телеметрических данных из 8640 наблюдений за 30 дней с дискретизацией 5 минут. Рассчитаны задержки, скользящие средние, дисперсии и трендовые показатели напряжения, тока, температуры, частоты, коэффициента мощности и активной мощности. Сравнены логистическая регрессия, Random Forest и Gradient Boosting. Для 30-минутного раннего предупреждения гибридная модель 0,4 LR + 0,6 RF получила F1=0,8895 и ROC-AUC=0,9888. Все 21 событие тестового периода были охвачены сигналом за 15–25 минут до начала смоделированной неисправности.

Ключевые слова:

линия электропередачи, временной ряд, прогнозирование риска, Random Forest, логистическая регрессия, Gradient Boosting, SCADA, раннее предупреждение, машинное обучение.

Machine learning algorithm for time-series-based forecasting of hazards in electric transmission lines

ABSTRACT

The paper proposes a time-series-based machine-learning method for forecasting hazardous conditions in electric transmission lines before

Key words:

transmission line, time series, risk



the actual fault occurs. A physically motivated synthetic telemetry dataset of 8,640 observations sampled every five minutes over 30 days was generated. Voltage, current, temperature, frequency, power factor and active-power lag, rolling-statistics and trend features were extracted. Logistic Regression, Random Forest and Gradient Boosting were compared. For a 30-minute early-warning task, the proposed 0.4 Logistic Regression + 0.6 Random Forest ensemble achieved $F1=0.8895$ and $ROC-AUC=0.9888$. All 21 test-period events were preceded by an alarm 15–25 minutes before the simulated fault onset.

forecasting, Random Forest, Logistic Regression, Gradient Boosting, early warning, SCADA, machine learning, fault prediction.

KIRISH

Elektr uzatish liniyalari elektr energetika tizimining ishlab chiqarish va iste'molchi o'rtasidagi asosiy bog'lovchi bo'g'inlaridan biridir. Liniyadagi qisqa tutashuv, kuchlanishning pasayishi, ortiqcha tok, qizish yoki boshqa anomal jarayonlar elektr ta'minotining uzilishi va tizim barqarorligining yomonlashishiga olib kelishi mumkin. Shu sababli monitoring tizimining vazifasi faqat sodir bo'lgan avariyaning qayd etish bilan cheklanmasligi, balki xavfning shakllanishini oldindan ko'rsatishi kerak.

Zamonaviy tadqiqotlarda vaqt bo'yicha ketma-ket o'lchovlardan foydalanish muhim yo'nalishga aylangan. Transmission-line ma'lumotlarini ketma-ketlik sifatida ishlatgan LSTM yondashuvlari fault detection va classification vazifalarida vaqt bog'lanishlarini modellashtiradi [1,2]. 2025-yilgi tadqiqotlarda TCN, BiLSTM va GRU kabi vaqt qatori modellarining transmission-line fault classification uchun qo'llanishi ham ko'rsatilgan [3]. Bu ishlar "hodisa sodir bo'lgandan keyin aniqlash" masalasini kuchli yechsa-da, operator uchun amaliy qiymatga ega bo'lgan savol — "hodisa boshlanishidan necha daqiqa oldin xavf oshayotganini bilish" — alohida prognozlash vazifasini talab qiladi.

Mazkur maqolada ana shu farq asosiy metodologik nuqta sifatida olinadi. Maqsad — elektr uzatish liniyasining telemetrik vaqt qatoridan foydalangan holda keyingi 30 daqiqada xavfli holat yuz berish ehtimolini hisoblaydigan algoritmi ishlab chiqish va uning samaradorligini statistik mezonlar orqali baholash.

Tadqiqotning ilmiy yangiligi

- hodisaning joriy holatini emas, keyingi 30 daqiqadagi xavfini bashorat qiluvchi nishon o'zgaruvchi shakllantirildi;
- telemetrik signalning qiymati bilan birga lag, sirpanma o'rtacha, standart og'ish va trend kabi vaqt qatori belgilarining yagona vektori ishlab chiqildi;
- fizik quvvat tenglamasi asosidagi P_{res} qoldiq belgisi vaqt qatori xususiyatlariga qo'shildi;
- Logistic Regression va Random Forest ehtimollarini 0,4/0,6 nisbatda birlashtiruvchi gibrid qaror mexanizmi taklif qilindi;
- modelning faqat $F1$ yoki Accuracy emas, balki oldindan ogohlantirish vaqti bilan ham baholanishi belgilandi.

Tadqiqot natijalari sintetik, fizik jihatdan asoslangan tajriba ma'lumotlariga tegishli. Shuning uchun ular real elektr tarmog'ining ekspluatatsion samaradorligi sifatida talqin qilinmaydi; real SCADA/PMU ma'lumotlarida qo'shimcha validatsiya talab etiladi.

MAVZUGA OID ADABIYOTLARNING TAHLILI

Transmission-line fault analysis bo'yicha ilmiy adabiyotlarda uchta asosiy yo'nalish ko'rinadi: signalni bevosita klassifikatsiya qilish, chuqur ketma-ketlik modellaridan foydalanish va gibrid/ansambl algoritmlar. Rafique, Fu va Mai LSTM asosidagi end-to-end yondashuvda elektr uzatish tarmog'ining operatsion ma'lumotlarini qo'lda feature extraction qilmasdan ketma-ketlik sifatida qayta ishlash mumkinligini ko'rsatgan [2]. Belagoune va hammualliflar esa PMU o'lchovlaridagi kuchlanish va tok ketma-ketliklarini LSTM orqali fault region, fault type va fault location masalalarida qo'llagan [1].



Random Forest ham elektr energetika obyektlarida ishonchli klassifikator sifatida keng qo'llanadi. 2020-yilgi tadqiqotda RF gibril sxema tarkibida transmission-line fault detection va classification uchun ishlatilgan [4]. HVDC liniyalari uchun RF asosidagi intelligent fault identification yondashuvida ko'p masshtabli signal belgilaridan foydalanilgan [5]. 2026-yilgi tadqiqotlarda ham RF va ensemble usullarining elektr fault diagnosis vazifalaridagi samaradorligi ko'rib chiqilgan [6]. Random Forest algoritmining klassifikatsiya vazifalaridagi ansambl tabiati Breiman tomonidan batafsil asoslangan [7]. Transmission-line fault detection va classification bo'yicha keyingi tadqiqotlarda ham Random Forest yondashuvlari qo'llangan [8,9].

Biroq mavjud ishlarning katta qismida maqsad faultning o'zini aniqlash yoki klassifikatsiya qilishdir. Ushbu maqolada esa label joriy o'lchovdagi threshold orqali emas, mustaqil ravishda modellashtirilgan latent hodisa va uning oldingi vaqt oralig'i asosida shakllantirildi. Bu yondashuv data leakage xavfini kamaytiradi va "oldindan prognozlash" bilan "hodisani aniqlash"ni ajratadi.

Adabiyotlar asosida tadqiqot bo'shlig'i

1-jadval. Mavjud yondashuvlar va mazkur tadqiqotdagi yechimning taqqoslanishi.

Yo'nalish	Kuchli tomoni	Cheklovi	Mazkur ishdagi yechim
LSTM/DRNN [1,2]	Ketma-ketlikdagi uzoq bog'lanishlarni o'rganadi	Hisoblash resursi va izohlash murakkabligi yuqori	Lag/rolling belgilar + RF
RF va gibril usullar [4-6,8,9]	Yuqori aniqlik, nonlinear bog'lanishlar	Ko'pincha hodisadan keyingi detection	Keyingi 30 min target
Signal transformatsiyasi [5]	Shovqinga chidamli feature extraction	Ko'p hollarda fault allaqachon mavjud	Trend va o'zgarish tezligi
Oddiy threshold monitoring	Sodda va tez	Oldindan xavfni ifodalamaydi	Ehtimollik asosidagi risk

Manba: muallif tomonidan ilmiy adabiyotlar asosida tuzilgan.

Shunday qilib, taklif etilayotgan yondashuv avvalgi maqoladagi "hozir nosozlik bormi?" masalasini takrorlamaydi. U "nosozlik hali boshlanmagan bo'lsa-da, uning ehtimoli oshyaptimi?" degan savolga javob beradi.

3. TADQIQOT METODOLOGIYASI (RESEARCH METHODOLOGY)

3.1. Vaqt qatori va ma'lumotlarni shakllantirish

Tajriba uchun 30 kunlik, 5 daqiqalik diskretlashga ega 8640 ta kuzatuvdan iborat vaqt qatori yaratildi. Har bir yozuvda vaqt tamg'asi, yuklama koeffitsiyenti, atrof-muhit harorati, shamol tezligi, liniya kuchlanishi V , tok I , o'tkazgich harorati T , chastota f , quvvat koeffitsiyenti $\cos\varphi$ va aktiv quvvat P saqlandi. Bu ma'lumotlar real operator telemekmetriyasi emas, balki fizik bog'lanishlarni saqlashga harakat qilingan eksperimental simulyatsiyadir.

Yuklama sutkalik sinusoidal komponent va kichik tasodifiy shovqin bilan modellashtirildi. Harorat yuklama va shamolga bog'landi. Kuchlanish yuklama ortishi bilan biroz kamayadigan, tok esa yuklamaga mutanosib bo'ladigan qilib olindi. Aktiv quvvat uch fazali tizimning soddalashtirilgan tenglamasi orqali hisoblandi.

$$P(t) = \sqrt{3} \cdot U(t) \cdot I(t) \cdot \cos\varphi(t) / 1000$$

70 ta hodisa oynasi vaqt o'qiga oldindan tanlangan latent jarayon sifatida kiritildi. Har bir hodisadan 30 daqiqa oldin signalning asta-sekin o'zgarishi modellashtirildi: kuchlanish pasaydi, tok va harorat o'sdi, chastota hamda quvvat koeffitsiyenti siljidi. Hodisa boshlanganida o'zgarishlar kuchaydi. Muhim jihati shundaki, target o'zgaruvchi biror kuzatilgan signal thresholdidan hosil qilinmadi.

3.2. Prognoz nishoni

Har bir t vaqti uchun $y(t)=1$, agar t dan keyingi 30 daqiqada kamida bitta fault kuzatilsa, aks holda $y(t)=0$ deb belgilandi. 5 daqiqalik diskretlashda 30 daqiqa oltita keyingi nuqtaga teng.



$y(t) = 1$, agar $\max\{F(t+1), \dots, F(t+6)\} = 1$; aks holda $y(t) = 0$

3.3. Vaqt bo'yicha ajratish

Ma'lumotlar tasodifiy aralashtirilmasdan xronologik tarzda 70/30 nisbatda ajratildi. Natijada 6043 ta yozuv o'qitish, 2591 ta yozuv test qismiga tushdi. Bunday ajratish kelajakdagi kuzatuvlarning o'tmishga "qaytib kirishi"ni cheklaydi va vaqt qatoridagi data leakage xavfini kamaytiradi.

2-jadval. Tajriba ma'lumotlar to'plamining asosiy statistik ko'rsatkichlari.

Ko'rsatkich	Qiymat
Kuzatuvlar soni	8640
Davomiylik	30 kun
Diskretlash	5 daqiqa
Hodisa oynalari	70
Training qismi	6043
Test qismi	2591
Test davridagi hodisalar	21
Prognoz gorizonti	30 daqiqa

Manba: muallif tomonidan Python muhitida yaratilgan sintetik tajriba ma'lumotlari asosida.

3.4. MATEMATIK MODEL VA BELGILARNI HISOBLASH

Vaqt qatori asosida prognozlashning asosiy g'oyasi bitta o'lchov qiymatini emas, uning oldingi qiymatlari va o'zgarish yo'nalishini birgalikda tahlil qilishdan iborat. Shu sababli har bir asosiy signal uchun uch turdagi vaqt belgisi hisoblandi: lag qiymatlar, sirpanma statistikalar va trend.

1) Kechikkan qiymatlar

$$x_{lag,k}(t) = x(t - k), k \in \{1, 3, 6\}$$

5 daqiqalik diskretlashda $k=1, 3$ va 6 mos ravishda $5, 15$ va 30 daqiqalik tarixni bildiradi.

2) Sirpanma o'rtacha va standart og'ish

$$\mu_6(t) = \frac{1}{6} \sum_{i=0}^5 x(t - i)$$

$$\sigma_6(t) = \sqrt{\frac{1}{6} \sum_{i=0}^5 (x(t - i) - \mu_6(t))^2}$$

3) 30 daqiqalik trend

$$S_6(t) = \frac{x(t) - x(t - 6)}{6}$$

S_6 musbat bo'lsa, signalning oxirgi 30 daqiqada o'sish tendensiyasi mavjud; manfiy qiymat esa pasayishni ko'rsatadi. Ayniqsa kuchlanishning manfiy trendi, haroratning musbat trendi va tokning musbat trendi oldindan xavfni ifodalovchi belgilar sifatida qaraldi.

4) Fizik qoldiq

O'lchangan aktiv quvvatning fizik hisoblangan qiymatdan farqi qo'shimcha diagnostik belgi sifatida olindi.

$$P_{model}(t) = \sqrt{3} \cdot U(t) \cdot I(t) \cdot \cos\varphi(t) / 1000$$

$$P_{res}(t) = P(t) - P_{model}(t)$$

Bu qoldiqning afzalligi shundaki, model faqat bitta thresholdga bog'lanmaydi. P, U, I va $\cos\varphi$ o'rtasidagi fizik munosabat buzilganda P_{res} kattalashadi.

5) Xavf ehtimolini birlashtirish

$$p_{hybrid}(t) = 0.4 \cdot p_{LR}(t) + 0.6 \cdot p_{RF}(t)$$

Yakuniy qaror $p_{hybrid} \geq 0.50$ bo'lganda "keyingi 30 daqiqada xavf" deb belgilandi. Signalning tasodifiy bir marta ko'tarilishidan keladigan yolg'on ogohlantirishlarni kamaytirish uchun ketma-ket ikki kuzatuvda threshold bajarilishi operator signali sifatida qabul qilindi.




Namunaviy hisob

1000-kuzatuv atrofidagi tanlangan yozuvda $U=220.04$ V, $I=154.90$ A va $\cos\varphi=0.9364$ bo'ldi. Hisoblashda $P_{model} = \sqrt{3} \times 220.04 \times 154.90 \times 0.9364 / 1000 = 55.28$ kW. Shu qiymat o'lchangan P bilan taqqoslanib Pres hisoblanadi.

3.5. TAKLIF ETILAYOTGAN ALGORITM VA APPARAT-DASTURIY ARXITEKTURA

Taklif etilayotgan algoritm besh bosqichdan iborat: 1) telemetriya oqimini qabul qilish; 2) tozalash va vaqt bo'yicha sinxronlash; 3) lag/rolling/trend belgilarini hisoblash; 4) LR va RF ehtimollarini hisoblash; 5) 30 daqiqalik xavf signalini operatorga chiqarish. Ushbu tuzilma Python muhitida prototip sifatida amalga oshirilishi, kelgusida SCADA serveri yoki edge-computing qurilmasiga ko'chirilishi mumkin.



1-rasm. Taklif etilayotgan apparat-dasturiy prognozlash jarayoni.

Manba: muallif tomonidan ishlab chiqilgan apparat-dasturiy arxitektura sxemasi.

Algoritmning pseudokodi

1. Telemetriya oqimidan U, I, T, f, cosφ va P ni o'qish.
2. Har bir signal uchun 5, 15 va 30 daqiqalik laglarni hisoblash.
3. Oxirgi 30 daqiqalik oyna uchun o'rtacha, standart og'ish va trendni aniqlash.
4. Pmodel va Pres ni fizik tenglama asosida hisoblash.
5. Tayyor feature vektorini LR va RF modellariga uzatish.
6. $phybrid(t) = 0.4 \cdot pLR(t) + 0.6 \cdot pRF(t)$ ni hisoblash.
7. Agar $phybrid(t) \geq 0.50$ ketma-ket ikki marta bajarilsa, oldindan ogohlantirish chiqarish.
8. Signalni vaqt tamg'asi va ehtimollik bilan jurnalga yozish.

Model parametrlarining tanlanishi

3-jadval. Mashinaviy o'qitish modellarining asosiy parametrlari.

Model	Asosiy parametrlar	Vazifasi
Logistic Regression	standardizatsiya; class_weight=balanced	Bazaviy ehtimollik modeli
Random Forest	160 daraxt; max_depth=10; min_leaf=3; balanced	Nonlinear vaqt belgilarini o'rganish
Gradient Boosting	120 estimator; depth=2; lr=0.06	Taqqoslash bazasi
Gibrid	0.4 LR + 0.6 RF; threshold 0.50	Yakuniy xavf ehtimoli

Manba: muallif tomonidan tajriba konfiguratsiyasi asosida tuzilgan.

Random Forest uchun 160 ta daraxt tanlanishi modelning barqarorligini oshirish va kichik o'zgarishlarga sezgirlikni kamaytirish maqsadida belgilandi. 10 maksimal chuqurlik va 3 minimal barg hajmi haddan tashqari moslashuvni cheklashga xizmat qiladi.

3.6. TAJRIBA DIZAYNI VA MA'LUMOTLARNING STATISTIK TAVSIFI

Eksperimentning muhim sharti - hodisa labelini bevosita input thresholdlaridan hosil qilmaslik. Shu sababli fault hodisalari vaqt o'qida latent hodisa oynalari sifatida alohida shakllantirildi. Hodisadan oldingi olti 5 daqiqalik nuqtada fizik signallarning yo'nalishli siljishi berildi. Natijada model xavfni aynan "hodisa allaqachon mavjud"ligi sababli emas, balki undan oldingi dinamik o'zgarishlarni o'rganish orqali prognozlaydi.

4-jadval. Tajribada foydalanilgan telemetrik signallarning bazaviy diapazonlari.

Signal	Bazaviy diapazon (taxminiy)	Modeldagi rol
--------	-----------------------------	---------------



U, V	≈218–222	Kuchlanish barqarorligi va trend
I, A	≈80–195	Yuklama va o'sish tezligi
T, °C	≈20–40	Issiqlik holati
f, Hz	≈49.85–50.05	Tarmoq chastotasi
cosφ	≈0.90–0.96	Quvvat sifati
P, kW	≈25–70	Fizik quvvat muvozanati

Manba: muallif tomonidan Python muhitida yaratilgan sintetik telemetriya modeli asosida.

Hodisadan oldingi o'zgarishlar

Hodisa oynasiga kirishdan oldingi 30 daqiqada kuchlanish o'rtacha 5,5 V ga pasayish komponentiga, tok 18 A gacha o'sish komponentiga, harorat 8 °C gacha ko'tarilish komponentiga ega bo'ldi. Chastota 0,08 Hz gacha, quvvat koeffitsiyenti esa 0,025 gacha siljidi. Hodisaning o'zida o'zgarishlar kuchaytirildi. Bu parametrlar real avariya normasi emas, tajriba uchun tanlangan signal amplitudalaridir.

Hisoblashning statistik ketma-ketligi

- 8640 yozuv ichidan dastlabki rolling oynalar olib tashlanib, 2591 ta test yozuvi qoldirildi;
- trainingda 435 ta, testda 183 ta "keyingi 30 daqiqada xavf" yozuvi mavjud bo'ldi;
- testdagi 21 ta hodisaning har biri uchun birinchi tasdiqlangan alarm va haqiqiy hodisa vaqti orasidagi farq hisoblandi;
- Precision, Recall, F1 va ROC-AUC bilan birga o'rtacha ogohlantirish vaqti asosiy amaliy mezon sifatida olindi.

Ushbu metodologiya vaqt qatori uchun muhim bo'lgan xronologik test tamoyiliga amal qiladi. Kelajakdagi real tizimda ham modelni qayta o'qitish vaqt bo'yicha bloklarga bo'lingan holda tashkil etilishi maqsadga muvofiq.

4. TAHLIL VA NATIJALAR (ANALYSIS AND RESULTS)


4.1. Algoritmarni taqqoslash

5-jadval. Modellarning prognozlash samaradorligi ko'rsatkichlari.

Model	Accuracy	Precision	Recall	F1	ROC-AUC
Logistic Regression	0.9734	0.7500	0.9344	0.8321	0.9898
Random Forest	0.9792	0.8909	0.8033	0.8448	0.9804
Gradient Boosting	0.9772	0.8735	0.7923	0.8309	0.9803
Gibrid LR+RF	0.9846	0.8994	0.8798	0.8895	0.9888

Manba: muallif tomonidan Python muhitida o'tkazilgan eksperiment natijalari asosida.


Natijalar gibrid modelning Precision=0,8994 va Recall=0,8798 qiymatlari orasida muvozanat yaratganini ko'rsatadi. F1=0,8895 bo'lib, uchta alohida model ichida eng yuqori qiymatga ega. ROC-AUC=0,9888 modelning normal va xavfli holatlarni ajratish qobiliyati yuqori ekanini ko'rsatadi. ROC-AUC mezoni klassifikatsiya modelining ajratish qobiliyatini baholashda keng qo'llanadi [10].



2-rasm. Algoritmning prognozlash samaradorligini taqqoslash.

Manba: muallif tomonidan Python muhitida yaratilgan eksperimental simulyatsiya natijalari.

4.2. Confusion matrix tahlili




3-rasm. Gibril modelning confusion matrix natijasi.

Manba: muallif tomonidan Python muhitida yaratilgan eksperimental simulyatsiya natijalari.

Test to'plamida 2390 ta normal holat to'g'ri normal deb, 161 ta xavfli holat to'g'ri xavf deb prognoz qilingan. 18 ta normal kuzatuv yolg'on alarm, 22 ta xavfli kuzatuv esa o'tkazib yuborilgan. Shu asosda Accuracy=0.9846, Precision=0.8994, Recall=0.8798 va F1=0.8895.

Elektr energetika uchun Recallning ma'nosi alohida muhim: xavfli hodisani o'tkazib yuborishning narxi yolg'on ogohlantirishdan yuqori bo'lishi mumkin. Shu sababli amaliy tizimda thresholdni 0,50 dan yuqori yoki pastga sozlash operatorning xavf siyosatiga bog'liq bo'lishi kerak. Klassifikatsiya ko'rsatkichlarini birgalikda talqin qilish zarurligi F1 va boshqa metrikalarni muhokama qiluvchi ishlarda ham qayd etilgan [11].


4.3. VAQT QATORI VA OLDINDAN OGOHLANTIRISH NATIJALARI



4-rasm. Nosozlikdan oldingi vaqt qatori va 30 daqiqalik xavf prognozi.

Manba: muallif tomonidan Python muhitida yaratilgan eksperimental simulyatsiya natijalari.

4-rasmda hodisaga yaqin vaqt oralig'ida kuchlanishning pasayishi va haroratning o'sishi bilan birga xavf ehtimolining ortishi kuzatiladi. Muhim jihati — modelning yuqori ehtimollik signali faultning o'zi boshlanganidan oldin paydo bo'ladi. Bu holat detection emas, prediction vazifasi bajarilganini ko'rsatadi.



5-rasm. 30 daqiqalik oldindan ogohlantirish ehtimolining o'zgarishi.

Manba: muallif tomonidan Python muhitida yaratilgan eksperimental simulyatsiya natijalari.

Test davridagi 21 ta hodisa bo'yicha ketma-ket ikki kuzatuv bilan tasdiqlangan birinchi alarmning o'rtacha oldindan ogohlantirish vaqti 19.76 daqiqa, medianasi 20 daqiqa bo'ldi. Minimal qiymat 15 daqiqa, maksimal qiymat 25 daqiqani tashkil etdi.


6-jadval. 30 daqiqalik oldindan ogohlantirish natijalari.

Mezon	Natija
Testdagi hodisalar	21
Signal bilan qamrab olingan hodisalar	21/21
Qamrov	100% (simulyatsiya testida)
O'rtacha lead time	19.76 min
Median lead time	20 min
Minimal lead time	15 min
Maksimal lead time	25 min
Ketma-ket tasdiq	2 ta 5-minutlik nuqta

Manba: muallif tomonidan Python muhitida o'tkazilgan simulyatsiya natijalari asosida.

Ushbu 100% qamrov faqat yaratilgan sintetik test stsenariysiga tegishli. Uni real elektr uzatish liniyalarida 100% fault prediction kafolati sifatida talqin qilish mumkin emas.

4.4. BELGILARNING AHAMIYATI VA MODELNI IZOH-LASH



6-rasm. Random Forest modelida asosiy vaqt qatori belgilarining ahamiyati.



Manba: muallif tomonidan Python muhitida yaratilgan eksperimental simulyatsiya natijalari.

Random Forest feature importance natijasida V_{slope6} eng katta ulushni (0,1404), joriy kuchlanish V 0,1205, temp_growth 0,0951, voltage_dev 0,0928 va T_{slope6} 0,0846 qiymatlarni egalladi. Bu natija xavfning oddiy absolyut qiymatdan ko'ra, signalning vaqt bo'yicha qaysi yo'nalishda va qanchalik tez o'zgarayotganiga bog'liqligini ko'rsatadi.

7-jadval. Random Forest modelida asosiy vaqt qatori belgilarining ahamiyati.

Belgi	Muhimlik	Talqin
V_{slope6}	0.1404	30 daqiqadagi kuchlanish trendi
V	0.1205	Joriy kuchlanish holati
temp _{growth}	0.0951	15 daqiqadagi harorat o'sishi
voltage _{dev}	0.0928	Nominal kuchlanishdan og'ish
T_{slope6}	0.0846	30 daqiqadagi harorat trendi
freq _{slope6}	0.0599	Chastota trendi
T_{std6}	0.0587	Harorat tebranishi
V_{lag1}	0.0480	5 daqiqalik tarixiy qiymat
freq	0.0479	Joriy chastota
V_{std6}	0.0476	Kuchlanish tebranishi

Manba: muallif tomonidan Random Forest modeli asosida hisoblangan.

Bu natija tadqiqotning asosiy g'oyasini qo'llab-quvvatlaydi: oldindan prognozlash uchun "signal qanchaga teng?" savolidan tashqari "signal oxirgi 30 daqiqada qanday o'zgaryapti?" savoli ham muhim. Shu sababli vaqt qatori belgilarini oddiy threshold monitoringdan ustun qo'yish mumkin.

Amaliy ishlash mexanizmi

Operator panelida har bir liniya uchun p_{hybrid} ehtimoli, so'nggi 30 daqiqadagi V va T trendi, P_{res} va oxirgi alarm vaqti ko'rsatilishi mumkin. Ehtimollik 0,50 dan oshib, ikki ketma-ket o'lchovda saqlansa, tizim "oldindan xavf" holatiga o'tadi.

4.5. MUHOKAMA

Natijalar vaqt qatori belgilaridan foydalanishning amaliy afzalligini ko'rsatadi. LSTM kabi chuqur ketma-ketlik modellari temporal bog'lanishlarni to'g'ridan-to'g'ri o'rganishi mumkin [1,2], biroq kichik prototipni ishlab chiqishda lag, rolling va trend belgilarini Random Forest bilan birlashtirish hisoblash jihatidan soddaroq va izohlash osonroqdir. Shu nuqtai nazardan maqoladagi model SCADA/edge monitoring uchun boshlang'ich algoritmik qatlam sifatida qaralishi mumkin.

Modelning yana bir afzalligi - targetning input thresholdidan bevosita hosil qilinmaganidir. Agar "fault" aynan $V < 220$ yoki $T > 35$ shartidan hosil qilinsa, model shu qoidani yodlab olib, yuqori $F1$ ko'rsatishi mumkin. Bunday vaziyat haqiqiy prognozlash emas. Mazkur ishda esa hodisa vaqt o'qida mustaqil latent stsensariy sifatida kiritilib, undan oldingi signal dinamikasi modelga o'rganish uchun berildi.

Cheklovlar

- ma'lumotlar sintetik bo'lib, real SCADA/PMU telemetriyasini to'liq almashtirmaydi;
- hodisalar soni va amplitudalari tajriba stsensariysiga bog'liq;
- model bir liniya va yagona 30 daqiqalik prognoz gorizontida tekshirildi;
- real tizimda sensor shovqini, ma'lumot uzilishi, kommunikatsiya kechikishi va mavsumiy rejimlar qo'shimcha muammo tug'dirishi mumkin;
- LSTM/TCN/GRU kabi chuqur vaqt qatori modellarini shu datasetda to'liq benchmark qilish kelgusi ish sifatida qoldirildi.

Amaliy joriy etish bo'yicha tavsiyalar

- SCADA yoki PMU oqimlarini yagona vaqt tamg'asi bo'yicha sinxronlashtirish;
- modelga faqat joriy qiymat emas, kamida 15–30 daqiqalik tarixni kiritish;
- thresholdni o'qitish davrida emas, alohida validatsiya qismida tanlash;
- alarmni bitta nuqta emas, ketma-ket ikki yoki uchta kuzatuv bilan tasdiqlash;



• modelni real hodisalar to'plami yig'ilgach qayta kalibrlash va drift monitoringini tashkil qilish.

NIST AI Risk Management Framework AI tizimlarida risklarni boshqarishni govern, map, measure va manage funksiyalari orqali uzluksiz tashkil etishni tavsiya qiladi [12]. Elektr energetika kabi kritik infratuzilmada prognoz modelining ishlash ko'rsatkichlarini muntazam o'lchash va nazorat qilish shu sababli alohida ahamiyatga ega.

XULOSA VA TAKLIFLAR

Tadqiqotda elektr uzatish liniyalaridagi xavfli holatlarni yuz berganidan keyin aniqlash emas, balki keyingi 30 daqiqa ichida yuz berishi mumkin bo'lgan hodisani oldindan prognozlash masalasi ko'rib chiqildi. 5 daqiqalik diskretlash bilan 30 kunlik 8640 ta fizik jihatdan asoslangan sintetik telemetriya yozuvi shakllantirildi. Vaqt qatorining lag, rolling-statistika va trend belgilariga fizik quvvat qoldig'i qo'shildi.

Tajriba natijasida Logistic Regression, Random Forest va Gradient Boosting modellari taqqoslandi. Eng barqaror yakuniy natija 0,4 Logistic Regression va 0,6 Random Forest ehtimollarini birlashtirgan gibrid modelda olindi: Accuracy=0,9846, Precision=0,8994, Recall=0,8798, F1=0,8895 va ROC-AUC=0,9888. Test davridagi 21 ta simulyatsion hodisaning barchasida kamida 15 daqiqalik oldindan signal qayd etildi; o'rtacha lead time 19,76 daqiqa bo'ldi.

Ilmiy jihatdan asosiy natija — vaqt qatorining trend va kechikkan qiymatlari xavfni joriy thresholdga qaraganda boyroq ifodalashi mumkinligi ko'rsatildi. Amaliy jihatdan esa taklif etilgan algoritm operatorga hodisa boshlanishidan oldin texnik tekshiruv, yuklamani qayta taqsimlash yoki boshqa himoya choralarini ko'rish uchun vaqt beruvchi dasturiy modulga aylantirilishi mumkin.

Takliflar

- real SCADA/PMU ma'lumotlarida kamida bir necha oy davomida validatsiya o'tkazish;
- 30, 60 va 120 daqiqalik prognoz gorizontlarini alohida sinash;
- real fault turlari bo'yicha multi-class risk modelini ishlab chiqish;
- RF bilan bir qatorda LSTM, GRU yoki TCN modelini qo'shib, chuqur vaqt qatori benchmarkini bajarish;
- modelning qarorlarini SHAP yoki permutation importance orqali operatorga izohlash;
- algoritmnii Python prototipidan SCADA/edge qurilmasidagi apparat-dasturiy majmuaga bosqichma-bosqich ko'chirish;
- real telemetriya to'plangach, false alarm/hour, missed-event rate va calibration kabi ekspluatatsion ko'rsatkichlarni ham joriy qilish.

ISO 50001 energiya boshqaruv tizimida energiya ma'lumotlaridan foydalanib o'lchash, natijalarni ko'rib chiqish va uzluksiz takomillashtirish tamoyillarini belgilaydi [13]. Mazkur tadqiqotdagi monitoring va prognozlash moduli bunday ma'lumotga asoslangan boshqaruv siklining texnik analitik qismi sifatida ko'rilishi mumkin.

Kelgusidagi ishning eng muhim yo'nalishi — sintetik tajribani real elektr uzatish liniyalarining SCADA/PMU ma'lumotlari bilan tekshirish, modelni kalibrlash va avariya oldi signallarining haqiqiy lead time taqsimotini aniqlashdir.

FOYDALANILGAN ADABIYOTLAR

1. Belagoune, S., Bali, N., Bakdi, A., Baadji, B., & Atif, K. (2021). Deep learning through LSTM classification and regression for transmission line fault detection, diagnosis and location in large-scale multi-machine power systems. *Measurement*, 177, 109330. <https://doi.org/10.1016/j.measurement.2021.109330>.
2. Rafique, F., Fu, L., & Mai, R. (2021). End to end machine learning for fault detection and classification in power transmission lines. *Electric Power Systems Research*, 199, 107430. <https://doi.org/10.1016/j.epsr.2021.107430>.
3. Tunio, M. F. et al. (2025). Performance Comparison Between Deep Learning Models for Fault Classification in Transmission Lines Using Time Series Data. *Energy Science & Engineering*. <https://doi.org/10.1002/ese3.70033>.



4. Balakrishnan, P. (2020). A new intelligent scheme for power system faults detection and classification: A hybrid technique. *International Journal of Numerical Modelling: Electronic Networks, Devices and Fields*, 33.
5. Wu, X. et al. (2020). A novel intelligent fault identification method based on random forests for HVDC transmission lines. *Scientific Reports*, 10, 5142.
6. Intelligent fault diagnosis in power systems using Random Forest and ensemble learning. (2026). *Measurement: Energy*, 10, 100098. <https://doi.org/10.1016/j.meae.2026.100098>.
7. Breiman, L. (2001). Random Forests. *Machine Learning*, 45, 5–32. <https://doi.org/10.1023/A:1010933404324>.
8. Momeni, M., Norouzi Nasab, A., & Abasi, M. (2026). Fault detection, classification, and location in transmission lines compensated with Unified Interphase Power Controller (UIPC) based on random forest algorithm. *Measurement*, 258, 119020. <https://doi.org/10.1016/j.measurement.2025.119020>.
9. Fonseca, G. A. et al. (2022). Fault Classification in Transmission Lines Using Random Forest and Notch Filter. *Journal of Control, Automation and Electrical Systems*, 33, 598–609. <https://doi.org/10.1007/s40313-021-00844-4>.
10. Fawcett, T. (2006). An introduction to ROC analysis. *Pattern Recognition Letters*, 27(8), 861–874. <https://doi.org/10.1016/j.patrec.2005.10.010>.
11. Chicco, D., & Jurman, G. (2020). The advantages of the Matthews correlation coefficient (MCC) over F1 score and accuracy in binary classification evaluation. *BMC Genomics*, 21, 6. <https://doi.org/10.1186/s12864-019-6413-7>.
12. Tabassi, E. (2023). Artificial Intelligence Risk Management Framework (AI RMF 1.0). NIST AI 100-1. National Institute of Standards and Technology. <https://doi.org/10.6028/NIST.AI.100-1>.
13. ISO. (2018). ISO 50001:2018 Energy management systems — Requirements with guidance for use. International Organization for Standardization.