UDK: 622.7:004.8

FOYDALI QAZILMALARNI MAYDALASH VA BOYITISH JARAYONLARINI SUN'IY INTELLEKT ASOSIDA OPTIMALLASHTIRISH

Serjanova Feriuza Iklasjan qizi
serjanovaferiuza3@gmail.com

Annotatsiya. Foydali qazilmalarni maydalash, yanchish, klassifikatsiyalash va flotatsion boyitish jarayonlari yuqori energiya sarfi, xomashyo xossalarining o'zgaruvchanligi hamda ko'p sonli boshqariluvchi parametrlarning o'zaro bog'liqligi bilan tavsiflanadi. Ushbu maqolada sun'iy intellekt (SI) yordamida maydalash-boyitish majmuasini yopiq siklda optimallashtirish konsepsiyasi ishlab chiqildi. Taklif etilgan yondashuv real vaqt sensor ma'lumotlari, mashinali o'qitish asosidagi yumshoq sensorlar, ko'p mezonli optimallashtirish, raqamli egizak va operator nazoratini birlashtiradi. Korxona ma'lumotlari taqdim etilmagani sababli metodologik tekshiruv ochiq adabiyotlarda qayd etilgan texnologik diapazonlarga mos sintetik ma'lumotlar asosida bajarildi. Chiziqli regressiya, Random Forest, Gradient Boosting va Extra Trees algoritmlari unumdorlik, maxsus energiya sarfi, P80, flotatsiya ajratib olish darajasi hamda konsentrat sifatini prognozlash uchun taqqoslandi. Natijalar kuchli nolinear maqsadlarda ansambl modellarining ustunligini, ayrim deyarli chiziqli ko'rsatkichlarda esa sodda regressiya ham raqobatbardosh ekanini hamda SI-yordamidagi set-point boshqaruvi energiya, maydalash mahsuloti barqarorligi va boyitish ko'rsatkichlarini bir vaqtning o'zida muvozanatlashtirish imkonini ko'rsatdi. Keltirilgan sonlar ishlab chiqarish tajribasi emas, balki yondashuvning ishlash tamoyilini namoyish etuvchi modellashtirish natijalaridir.

Kalit so'zlar: sun'iy intellekt; foydali qazilmalarni boyitish; maydalash; yanchish; SAG tegirmoni; flotatsiya; mashinali o'qitish; raqamli egizak; jarayonni optimallashtirish.

Abstract. Crushing, grinding, classification and flotation are energy-intensive and strongly nonlinear mineral-processing operations. This study proposes a closed-loop artificial-intelligence framework that integrates plant sensors, machine-learning soft sensors, multi-objective optimization, a digital twin and human supervision. Because mine-specific industrial data were not available, a transparent simulation-based validation was conducted using synthetic operating ranges derived from international literature. Linear regression, Random Forest, Gradient Boosting and Extra Trees were compared for throughput, specific energy, product P80, flotation recovery and concentrate-grade prediction. Nonlinear ensemble models showed the strongest predictive performance for the most nonlinear targets, while simpler linear models remained competitive for near-linear targets. An illustrative closed-loop scenario demonstrated the potential to reduce specific energy and particle-size variability while increasing throughput, recovery and concentrate grade. The numerical values are methodological simulation results and are not presented as field-tested gains.

Keywords: artificial intelligence; mineral processing; comminution; grinding; flotation; machine learning; digital twin; process optimization.

Аннотация. В статье предложена замкнутая система оптимизации процессов дробления, измельчения, классификации и флотационного обогащения на основе искусственного интеллекта. Подход объединяет данные технологических датчиков, модели машинного обучения, многокритериальную оптимизацию, цифровой двойник и контроль оператора. В связи с отсутствием производственных данных методическая проверка выполнена на прозрачном

© Ushbu material Creative Commons Attribution 4.0 International (CC BY 4.0) litsenziyasi asosida tarqatiladi.

синтетическом наборе данных, сформированном в диапазонах, соответствующих международной литературе. Сравнены линейная регрессия, Random Forest, Gradient Boosting и Extra Trees для прогноза производительности, удельной энергии, P80, извлечения и качества концентрата. Результаты моделирования показывают перспективность интегрированного управления, однако не интерпретируются как фактические показатели конкретного предприятия.

Ключевые слова: искусственный интеллект; обогащение полезных ископаемых; дробление; измельчение; флотация; машинное обучение; цифровой двойник; оптимизация.

KIRISH

Foydali qazilmalarni qayta ishlash zanjirida maydalash va boyitish bosqichlari tayyor mahsulot tannarxi, metall ajratib olish darajasi va energiya samaradorligini belgilovchi asosiy bo‘g‘inlardan hisoblanadi. Ayniqsa, ruda tarkibining bir smenadan ikkinchisiga o‘zgarishi, qattiqlik va yoriqlilikning fazoviy notekisligi, oziqlantirish granulometriyasining beqarorligi hamda uskunalarning eskirishi natijasida an’anaviy doimiy set-pointlar optimal holatdan tez chetga chiqadi. Mashinali o‘qitish bo‘yicha keng qamrovli sharhlar mineralni qayta ishlashda ma’lumotlarga asoslangan modellashtirish, nosozliklarni aniqlash va mashina ko‘rishi eng faol yo‘nalishlar ekanini ko‘rsatadi (1.2).

Maydalash-yanchish bosqichi ko‘p boyitish fabrikalarida elektr energiyasining eng yirik iste’molchisi bo‘lib, u nafaqat o‘z energiya sarfi, balki keyingi flotatsiya samaradorligi uchun zarur bo‘lgan zarracha o‘lchami va minerallarning ochilish darajasini ham belgilaydi. SAG tegirmonlari bo‘yicha zamonaviy tadqiqotlarda aylanish tezligi, tegirmonga kiruvchi suv, oziqlantirish granulometriyasi, ruda qattiqligi va quvvat yuklamasi kabi omillarning unumdorlikka nolinear ta’siri qayd etilgan; vaqt kechikishlarini hisobga oluvchi RNN va ansambl modellar klassik regressiyadan yuqori aniqlik ko‘rsatgan (3.4). Shuningdek, ekspert bilimlari, CatBoost va evolyutsion algoritmlarni birlashtirgan tizimlar SAG set-pointlarini doimiy yangilash orqali yuqori unumdorlikka erishish konsepsiyasini taklif etadi (5.6).

Boyitish bosqichida esa flotatsiya jarayoni pulpa pH si, reagent sarfi, havo berish, ko‘pik qatlami chuqurligi, zarracha o‘lchami, mineral sirtining fizik-kimyoviy xususiyatlari va xomashyo tarkibining o‘zaro ta’siriga bog‘liq. Shu sababli bitta empirik tenglama barcha rejimlarni qamrab ololmaydi. So‘nggi ishlarda Random Forest, sun’iy neyron tarmoqlar, chuqur o‘qitish, ConvLSTM va gibrid ansambl modellar grade/recovery ni prognozlash, ko‘pik holatini tanish va reagent set-pointlarini tavsiya qilishda qo‘llanmoqda (7.8.9).

SI texnologiyalarining eng muhim afzalligi alohida model aniqligidan ko‘ra, ularni real vaqt qaror sikliga birlashtirish imkonidir. Raqamli egizak jarayonning virtual nusxasi sifatida yangi boshqaruv parametrlarini xavfsiz sinab ko‘rish, model xatosini kuzatish va texnologik cheklovlarni tekshirish imkonini beradi. Pilot flotatsiya qurilmasida adaptiv raqamli egizak parametrlarni yangi xomashyo sharoitlariga moslashtirish zarurligini ko‘rsatgan (10). Fizik qonunlarni neyron tarmoq yo‘qotish funksiyasiga kirituvchi physics-informed yondashuvlar esa ma’lumotlar taqsimoti o‘zgarganda sof data-driven modellarga nisbatan yaxshiroq umumlashuv berishi mumkin (11).

Mazkur tadqiqotning maqsadi maydalash va boyitish jarayonlarini sun’iy intellekt asosida integrallashgan holda optimallashtirish metodologiyasini ishlab chiqish va uni takrorlanuvchi modellashtirish ssenariysi orqali baholashdan iborat. Vazifalar quyidagilar: 1) maydalash-boyitish zanjiridagi asosiy ma’lumot oqimlarini aniqlash; 2) unumdorlik, energiya, P80, recovery va konsentrat sifatini bashorat qiluvchi modellarni taqqoslash; 3) ko‘p mezonli yopiq siklli boshqaruv tamoyilini shakllantirish; 4) an’anaviy va SI-yordamidagi boshqaruv natijalarini metodik ssenariyda solishtirish.

© Ushbu material Creative Commons Attribution 4.0 International (CC BY 4.0) litsenziyasi asosida tarqatiladi.

Ilmiy yangilik — maydalash va flotatsiyani bir-biridan ajratilgan lokal jarayonlar sifatida emas, balki P80 orqali o‘zaro bog‘langan yagona optimallashtirish konturi sifatida ko‘rishdadir.

Asosiy qism

Optimallashtirish mezonlari va texnologik ko‘rsatkichlar

Maydalash konturining asosiy samaradorlik ko‘rsatkichi sifatida maxsus energiya sarfi E_s tanlandi. U tegirmon yoki maydalash konturining o‘rtacha elektr quvvati P ning massa unumdorligi Q ga nisbatidan aniqlanadi: E_s = P / Q, kWh/t. Ushbu ko‘rsatkichni yolg‘iz minimallashtirish yetarli emas, chunki energiyani keskin kamaytirish mahsulotning P80 qiymatini yiriklashtirishi va minerallarning ochilish darajasini pasaytirishi mumkin. Shu bois energiya, unumdorlik va granulometriya birgalikda baholanadi (3.4).

Flotatsiya uchun metallurgik ajratib olish darajasi R va konsentratdagi foydali komponent miqdori G_c asosiy natijaviy ko‘rsatkichlar sifatida qabul qilindi. Soddalashtirilgan massa balansi bo‘yicha R = (C·c)/(F·f) × 100%, bu yerda F va C — oziqlantirish hamda konsentrat massasi, f va c — tegishli foydali komponent tarkibidir. Amaliy boshqaruvda yuqori recovery ayrim holatlarda konsentrat sifatining pasayishi hisobiga erishilishi mumkin; shu sababli SI optimallashtiruvchisi ikkala maqsadni ham muvozanatlashtirishi kerak (7.12).

Taklif etilgan ko‘p mezonli maqsad funksiyasi J = w1·E_norm + w2·|P80−P80*|/P80* − w3·Q_norm − w4·R_norm − w5·G_c,norm + w6·C_reagent ko‘rinishida ifodalandi. Bu yerda P80* — flotatsiya uchun maqsadli zarracha o‘lchami, C_reagent — reagent sarfining normallashtirilgan qiymati, w1–w6 esa texnologik va iqtisodiy ustuvorlik koeffitsiyentlaridir. Optimallashtirish uskunaning ruxsat etilgan tezligi, quvvat cheklovi, suv balansi, nasos-gidrotsiklon o‘tkazuvchanligi, pH va reagent dozasi diapazonlari bilan chegaralanadi.

Integrallashgan ma’lumot arxitekturasi

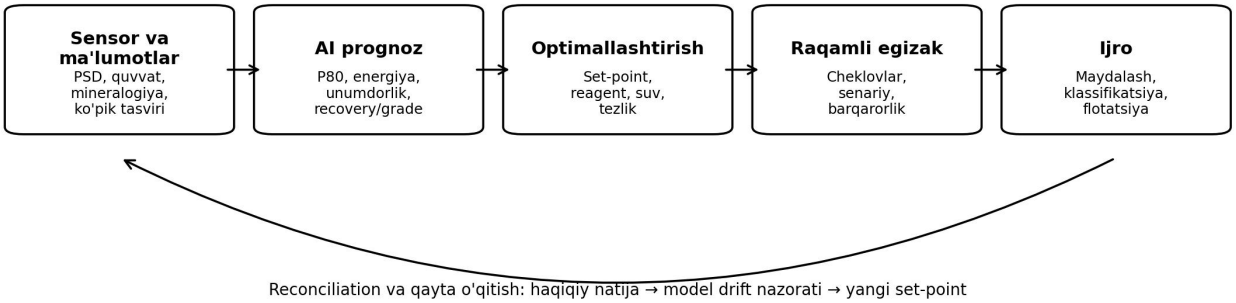
SI tizimining ishonchliligi sensorlarning sonidan ko‘ra ma’lumotlarning vaqt bo‘yicha moslashtirilishi, kalibrlanishi va texnologik ma’nosiga bog‘liq. AutoML bo‘yicha sanoat case-studylari xatoli nuqtalarni filtrlash, vaqt rezolyutsiyasini bir xil qilish va to‘g‘ri feature tanlash model sifatiga bevosita ta’sir qilishini ko‘rsatadi (13). Onlayn zarracha o‘lchami monitoringi konveyer tasvirlari va chuqur segmentatsiya yordamida rivojlanib, maydalash konturiga tezkor qayta aloqa berish imkonini kengaytirmoqda (14).

1-jadval. Maydalash-boyitish majmuasida SI uchun ma’lumot manbalari va boshqaruv vazifalari

Ma’lumot guruhi	Asosiy o‘zgaruvchilar	SI vazifasi	Boshqaruv ta’siri
Ruda va oziqlantirish	F80, qattiqlik, mineralogiya, grade, namlik	Feed-forward prognoz	Maydalagich gap, tegirmon rejimi, blending
Maydalash/yanchish	Quvvat, tezlik, suv, ball load, bosim, P80	Energiya, P80 va unumdorlik soft-sensori	Tezlik, suv, feed rate set-pointi
Klassifikatsiya	Siklon bosimi, zichlik, oqim, d50	Circulating load va cut-size prognozi	Nasos tezligi, suv taqsimoti
Flotatsiya	pH, reagent, havo, froth	Recovery/grade va	Reagent, havo, pulp

© Ushbu material Creative Commons Attribution 4.0 International (CC BY 4.0) litsenziyasi asosida tarqatiladi.

Ma'lumot guruhi	Asosiy o'zgaruvchilar	SI vazifasi	Boshqaruv ta'siri
	depth, ko'pik tasviri	froth holati	level
Mahsulot sifati	Onlayn analizator, laboratoriya grade	Model drift va reconciliation	Modelni qayta o'qitish, kalibrlash
Raqamli egizak	Tarix + fizik model + cheklovlar	What-if va risk tekshiruvi	Operatorga xavfsiz tavsiya



Yopiq siklli AI boshqaruv arxitekturasi

1-rasm. Maydalash va boyitish jarayonlari uchun yopiq siklli SI boshqaruv arxitekturasi.

Mashinali o'qitish modellari va validatsiya

Prognoz qatlamida chiziqli regressiya bazaviy va izohlanadigan model sifatida, Random Forest, Gradient Boosting va Extra Trees esa nolinear bog'lanishlarni ushlash uchun tanlandi. Ushbu algoritmlar mineralni qayta ishlashda kichik va o'rta hajmdagi jadval ma'lumotlarida keng qo'llanadi hamda ANN bilan bir qatorda kuchli natijalar beradi (1.2.7). Modellar alohida maqsadlar uchun o'qitildi: SAG/maydalash konturida Q, E_s va P80; flotatsiyada esa recovery va konsentrat grade.

Korxona ma'lumotlari taqdim etilmaganligi sababli, real ishlab chiqarish kuzatuvlari sifatida ko'rsatish mumkin bo'lmagan sonlarni o'ylab topishdan qochish maqsadida metodik tekshiruv sintetik datasetda bajarildi. Maydalash qismi 420 ta, flotatsiya qismi 380 ta shartli texnologik intervaldan iborat bo'ldi. Parametr diapazonlari SAG va flotatsiya bo'yicha xalqaro ishlarda uchraydigan tartiblarga mos ravishda tanlandi (3.5.6.8.9). Ma'lumotlarning 78% o'qitish, 22% test uchun ajratildi; barcha modellar bir xil test to'plamida R^2, MAE va RMSE orqali baholandi.

Sintetik funksiyalarda jarayon fizikasi bilan mos keluvchi nolinear elementlar kiritildi: ruda qattiqligi va F80 ortishi energiya sarfi hamda P80 ni oshirdi; tegirmon tezligi va suv miqdori ma'lum diapazongacha mahsulot maydaligini yaxshiladi; flotatsiyada esa pH, collector, havo va P80 uchun optimal zonalar shakllantirildi. Tasodifiy shovqin o'lchanmagan geologik va operatsion omillarni imitasiya qildi. Bunday yondashuv real kon uchun tayyor model emas, balki algoritmlar va boshqaruv arxitekturasini shaffof ravishda sinash vositasidir.

© Ushbu material Creative Commons Attribution 4.0 International (CC BY 4.0) litsenziyasi asosida tarqatiladi.

Yopiq siklli SI boshqaruvi

Yopiq siklda model faqat prognoz bermaydi, balki ruxsat etilgan parametrlar ichida nomzod set-pointlarni baholaydi. Maydalash konturida SI tegirmon tezligi, suv berish, ball load va feed rate o'zgarishlarining unumdorlik, P80 va energiyaga birgalikdagi ta'sirini ko'radi. Flotatsiya konturida esa pH, collector/frother, havo sarfi va froth depth kombinatsiyalari recovery–grade kompromissi bo'yicha tanlanadi. Evolyutsion va ko'p mezonli optimallashtirishning SAG jarayoniga tatbiqi Pareto-optimal set-pointlar operatorga bitta qat'iy qiymat o'rniga sharoitga mos tanlovlar berishini ko'rsatadi (5.6).

Raqamli egizak yangi tavsiya qilingan set-pointni avval virtual konturda tekshiradi. U suv va quvvat limitlari, minimal/ maksimal tezlik, siklon yuklamasi, reagent diapazoni va mahsulot sifati kabi cheklovlarni buzadigan qarorlarni rad etadi. Ohenoja va hammualliflar adaptiv raqamli egizak xomashyo xususiyatlari o'zgarganda parametrlarni yangilash zarurligini amaliy pilot misolida ko'rsatgan (10). Shu sababli taklif etilgan tizimda operator yakuniy qaror egasi bo'lib qoladi, SI esa tavsiya beruvchi va xavfni oldindan ko'rsatuvchi qatlam vazifasini bajaradi.

Prognoz modellarining aniqligi

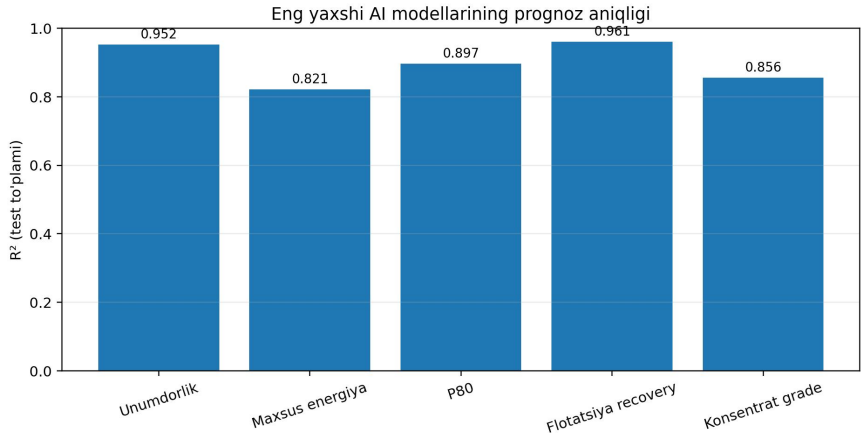
2-jadval. Sintetik test to'plamida prognoz modellarining aniqligi

Maqsad	Model	R^2	MAE	RMSE
Unumdorlik	Chiziqli regressiya	0.952	23.23	28.82
Unumdorlik	Random forest	0.922	29.39	36.79
Unumdorlik	Gradient boosting	0.938	26.30	32.96
Unumdorlik	Extra trees	0.930	28.01	35.01
Maxsus energiya	Chiziqli regressiya	0.666	0.66	0.83
Maxsus energiya	Random forest	0.774	0.55	0.68
Maxsus energiya	Gradient boosting	0.821	0.48	0.60
Maxsus energiya	Extra trees	0.764	0.57	0.69
P80	Chiziqli regressiya	0.897	12.88	16.36
P80	Random forest	0.833	15.87	20.80
P80	Gradient boosting	0.858	14.88	19.21
P80	Extra trees	0.852	15.10	19.57
Flotatsiya recovery	Chiziqli regressiya	0.722	2.82	3.45
Flotatsiya recovery	Random forest	0.946	1.13	1.52
Flotatsiya recovery	Gradient boosting	0.961	1.00	1.30
Flotatsiya recovery	Extra trees	0.956	1.06	1.37
Konsentrat grade	Chiziqli regressiya	0.856	0.62	0.80

© Ushbu material Creative Commons Attribution 4.0 International (CC BY 4.0) litsenziyasi asosida tarqatiladi.

Maqsad	Model	R^2	MAE	RMSE
Konsentrat grade	Random forest	0.762	0.84	1.03
Konsentrat grade	Gradient boosting	0.768	0.82	1.01
Konsentrat grade	Extra trees	0.781	0.79	0.98

Model solishtiruvi chiziqli yondashuv jarayonning barcha nolinear bog'lanishlarini to'liq ushlay olmasligini ko'rsatdi. Eng yuqori natijalar quyidagicha bo'ldi: unumdorlik uchun Chiziqli regressiya (R^2=0.952); maxsus energiya uchun Gradient boosting (R^2=0.821); P80 uchun Chiziqli regressiya (R^2=0.897); flotatsiya recovery uchun Gradient boosting (R^2=0.961); konsentrat grade uchun Chiziqli regressiya (R^2=0.856). Bu farq maydalash va flotatsiya jarayonlarida optimal zonalar, thresholdlar hamda o'zaro ta'sirlarning mavjudligi bilan izohlanadi. Real korxonada yakuniy model vaqt bo'yicha ajratilgan validatsiya va yangi ruda bloklarida out-of-sample sinov orqali tanlanishi lozim.



2-rasm. Har bir maqsad bo'yicha eng yaxshi modelning R^2 ko'rsatkichi (sintetik test to'plami).

SI-yordamidagi optimallashtirish ssenariysi

3-jadval. Yopiq siklli SI ssenariysida bazaviy va optimallashtirilgan ko'rsatkichlar

Ko'rsatkich	Bazaviy holat	SI-yordamidagi holat	Nisbiy o'zgarish
Maxsus energiya (kWh/t)	11.05	10.53	-4.8%
Mahsulot P80 (mkm)	139.71	133.51	-4.4%
Unumdorlik (t/soat)	854.16	856.84	+0.3%
Flotatsiyada ajratib olish (%)	82.49	89.37	+8.3%
Konsentrat tarkibi (%)	23.65	23.70	+0.2%

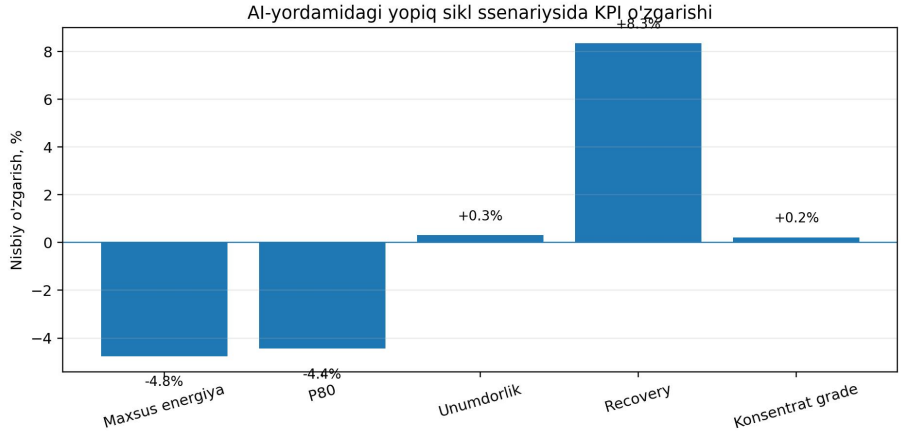
Metodik yopiq sikl ssenariysida set-pointlar fizik jihatdan maqbul markaziy zonalarga faqat cheklangan miqdorda yaqinlashtirildi. Natijada o'rtacha maxsus energiya 11.05 dan 10.53 kWh/t gacha o'zgardi (-4.8%), mahsulot P80 esa 139.7 dan 133.5 mkm gacha o'zgardi. Shu bilan birga hisoblangan

© Ushbu material Creative Commons Attribution 4.0 International (CC BY 4.0) litsenziyasi asosida tarqatiladi.

o‘rtacha unumdorlik 854 dan 857 t/soat gacha o‘zgardi (+0.3%). Bu sonlar ma’lum bir fabrikaga tegishli iqtisodiy kafolat emas; ular ko‘p mezonli boshqaruvning qanday ishlashini ko‘rsatadigan sintetik natijalardir.

Flotatsiya konturida yaxshilangan P80 va boshqariluvchi pH, reagent, havo hamda froth-depth parametrlarini optimal zonaga yaqinlashtirish natijasida model bo‘yicha o‘rtacha recovery 82.49% dan 89.37% gacha, konsentrat grade esa 23.65% dan 23.70% gacha o‘zgardi. Bu yerda muhim jihat faqat o‘rtacha qiymatning oshishi emas, balki maydalash va boyitish set-pointlarining bitta maqsad funksiyasida bog‘lanishidir: tegirmonda keragidan ortiq mayda mahsulot hosil qilish flotatsiya uchun har doim ham foydali emas, shuning uchun SI energiya va metallurgik natijani birga baholaydi.

Sanoat tadqiqotlari ham shu yo‘nalishni qo‘llab-quvvatlaydi. SAG jarayonida mashinali o‘qitish va statistik modellashtirish ishlab chiqarish hamda energiya uchun sezilarli optimallashtirish potensialini ko‘rsatgan (3); CatBoost va evolyutsion algoritmlar real katta hajmli industrial datasetlarda throughput va circulating load uchun yuqori aniqlikdagi modellarga asos bo‘lgan (5.6). Flotatsiya bo‘yicha esa ANN va genetik algoritmga asoslangan monitoring-optimallashtirish tizimlari sanoat sharoitidagi ma’lumotlarda tezkor tavsiya berish imkonini ko‘rsatgan (12).



3-rasm. SI-yordamidagi ssenariyda asosiy KPIlarning bazaviy holatga nisbatan o‘zgarishi.

Flotatsiyani real vaqt monitoring qilishda mashina ko‘rishi

Flotatsiya natijasiga tezkor ta’sir qilish uchun laboratoriya tahlilining kechikishi muhim muammo hisoblanadi. Ko‘pik tasvirlari esa kamera orqali sekundlar ichida olinadi va bubble size, texture, mobility, color hamda stability kabi yashirin holat belgilarini aks ettiradi. Chuqur o‘qitish asosidagi froth-image tahlili transfer learning, CNN va zamonaviy vizual arxitekturalar yordamida operator ko‘rishiga yaqin yoki ayrim vazifalarda undan barqarorroq soft-sensor yaratish imkonini bermoqda (8.15).

FlotationNet ierarxik chuqur tarmog‘i temir va kremniy komponentlari uchun recovery/grade xaritalashini yaxshilash maqsadida ishlab chiqilgan (9). Keyingi tadqiqotlarda tasvir va vaqt o‘lchamini birlashtiruvchi ConvLSTM, shuningdek, sanoat ko‘pik tasvirlaridan grade aniqlash uchun gibrid feature extraction yondashuvlari taklif qilindi (12.15). Bunday soft-sensorlar reagentni faqat laboratoriya natijasi kelgandan keyin emas, balki ko‘pik holati o‘zgargan paytda moslashtirishga imkon beradi.

Biroq tasvir modeli konlararo to‘g‘ridan-to‘g‘ri ko‘chirilmasligi kerak. Kamera burchagi, yoritish, suv sifati, mineralogiya, reagent turi va ko‘pik rangining o‘zgarishi data drift keltirib chiqaradi. Shu sababli model confidence, out-of-distribution flag va davriy qayta kalibrlash bilan ishlashi lozim. Recent

© Ushbu material Creative Commons Attribution 4.0 International (CC BY 4.0) litsenziyasi asosida tarqatiladi.

reviewlar katta, sifatli va markirovka qilingan froth-image bazalari yetishmasligini ham asosiy cheklov sifatida ko‘rsatadi (8).

Olingan metodik natijalar SI ni mineralni qayta ishlashda alohida “aqlli model” sifatida emas, balki uch qatlamli tizim — soft-sensor, optimallashtiruvchi va nazorat qiluvchi raqamli egizak sifatida qurish maqsadga muvofiqligini ko‘rsatadi. Birinchi qatlam o‘lchash qiyin bo‘lgan P80, circulating load, recovery yoki grade ni mavjud sensorlardan baholaydi; ikkinchi qatlam texnologik set-pointlarni qidiradi; uchinchi qatlam esa tavsiyaning uskunaviy va texnologik cheklovlarga mosligini tekshiradi. McCoy va Auret, shuningdek Gomez-Flores va hammualliflar AI ni mineralni qayta ishlashda aynan jarayon konteksti va ma’lumot sifati bilan bog‘lash zarurligini ta’kidlaydi (1.2).

Maydalash bosqichida SI joriy etish uchun eng tez iqtisodiy effekt odatda “soft sensor + advisory optimization” kombinatsiyasidan kelishi mumkin. Dastlab model operatorga kelasi 5–15 daqiqadagi throughput, P80 va quvvat yuklamasini prognoz qiladi. Keyin optimallashtiruvchi ruxsat etilgan oraliqda tezlik va suv bo‘yicha 3–5 ta set-point variantini tavsiya etadi. Operator tavsiyani qabul qilgach, natija avtomatik ravishda tarixga yoziladi. Bunday human-in-the-loop bosqich to‘liq avtonom boshqaruvga o‘tishdan oldin modelning haqiqiy qiymatini va noto‘g‘ri tavsiya chastotasini aniqlashga yordam beradi (4.5).

Boyitish bosqichida esa bir nechta sifat maqsadlari mavjudligi sababli ko‘p mezonli boshqaruv zarur. Masalan, collector dozasi oshishi qisqa muddatda recovery ni ko‘tarishi, biroq selektivlik pasayishi va reagent xarajatini oshirishi mumkin. Shu sababli optimallashtirish funksiyasiga faqat recovery emas, konsentrat grade, reagent sarfi, downstream metallurgiya talabi va hatto suv aylanishi kiritilishi kerak. Jo va hammualliflarning ko‘p bosqichli rougher-cleaner-scavenger flotatsiya zanjiri uchun ansambl modeli alohida bosqichlarning natijasini bog‘lash muhimligini ko‘rsatadi (7).

Physics-informed va hybrid modellarning kelajagi ayniqsa istiqbolli. Sof data-driven model o‘zi ko‘rmagan ruda turi yoki g‘ayrioddiy ish rejimida fizik jihatdan mantiqsiz javob berishi mumkin. Fizik mass-balance, kinetika yoki energiya cheklovlarini loss function yoki post-processing orqali kiritish modelning umumlashuvini yaxshilaydi. Nasiri va hammualliflar flotatsiya grade prognozida fizik modelni neyron tarmoq bilan birlashtirish sof ma’lumot modeliga nisbatan yaxshiroq generalizatsiya berganini ko‘rsatgan (11).

Sensor fusion ham tizim barqarorligini oshiradi. Faqat bitta onlayn analizator yoki bitta kamera ishlamay qolsa, butun SI konturi ishonchsiz bo‘lib qolmasligi kerak. Zarracha o‘lchami uchun kamera, lazer granulometriya va siklon parametrlarini; flotatsiya uchun ko‘pik tasviri, havo oqimi, pH va onlayn grade ni birlashtirish “redundant intelligence” yaratadi. Mineral boyitishda sensor-based sorting va sensor fusion bo‘yicha sharhlar turli sezgirlikdagi sensorlarni birlashtirish xomashyoni oldindan saralash va ortiqcha energiya sarfini kamaytirish uchun foydali ekanini ko‘rsatadi (2.14).

Amaliy joriy etishda texnologik kiberxavfsizlik va data governance masalalari ham e’tibordan chetda qolmasligi kerak. Model versiyasi, o‘qitilgan dataset davri, feature lar ro‘yxati, operator qabul qilgan tavsiya va real natija audit jurnali sifatida saqlanishi zarur. Data drift aniqlansa, model avtomatik boshqaruvdan advisory rejimga qaytarilishi kerak. Modelning yuqori R^2 ko‘rsatkichi xavfsizlik yoki metallurgik barqarorlikning o‘zi bilan tenglashtirilmaydi.

Ushbu ishning asosiy cheklovi — natijalar sintetik ma’lumotlarda olinganidir. Shuning uchun 3-jadval va 3-rasmdagi o‘zgarishlarni aniq bir boyitish fabrikasiga ko‘chirish mumkin emas. Real pilotda kamida bir necha oy davomida ruda bloklari, smena, liner eskirishi, reagent partiyasi va mavsumiy suv sifati kabi omillar bo‘yicha vaqtli validatsiya o‘tkazilishi lozim. Bundan tashqari, iqtisodiy baholash

© Ushbu material Creative Commons Attribution 4.0 International (CC BY 4.0) litsenziyasi asosida tarqatiladi.

energiya narxi, reagent narxi, metall narxi, qo‘shimcha konsentrat miqdori, model infratuzilmasi va texnik xizmat xarajatlarini birlashtirishi kerak.

Sanoatga joriy etishning bosqichma-bosqich modeli

Amaliy nuqtai nazardan SI tizimini birdan to‘liq avtomatik boshqaruvga ulash tavsiya etilmaydi. Birinchi bosqichda sensorlar va laboratoriya ma’lumotlari yagona vaqt shkalasiga keltiriladi, tag-lar standartlashtiriladi va ma’lumot sifati KPIlari belgilanadi. Ikkinchi bosqichda soft-sensorlar faqat monitoring rejimida ishlaydi; uchinchi bosqichda operatorga tavsiyalar beriladi; to‘rtinchi bosqichda esa faqat oldindan tasdiqlangan xavfsiz diapazonlarda bounded closed-loop nazorat yoqiladi. Bu yondashuv model xatolarini texnologik xavfga aylantirmasdan SI qiymatini bosqichma-bosqich isbotlash imkonini beradi.

Har bir bosqich uchun qabul mezoni oldindan belgilanadi. Masalan, P80 soft-sensori uchun vaqt bo‘yicha alohida test davrida MAE, energiya modeli uchun xatolik va bias, flotation soft-sensori uchun recovery/grade xatosi, advisory rejim uchun operator qabul qilgan tavsiyalar ulushi hamda tavsiya bajarilgandan keyingi real KPI o‘zgarishi kuzatiladi. Faqat barqaror natija va drift nazorati mavjud bo‘lgandagina keyingi avtomatlashtirish darajasiga o‘tiladi.

4-jadval. SI tizimini boyitish fabrikasiga joriy etish bosqichlari va nazorat mezonlari

Bosqich	**Asosiy ish**	**Chiqish natijasi**	**Keyingi bosqichga o‘tish mezoni**
1. Data foundation	Sensor audit, historian, vaqt sinxroni, laboratoriya bog‘lash	Tozalangan va kuzatiladigan dataset	Missing data va tag xatolari nazorat ostida
2. Soft-sensor	P80, energiya, recovery/grade prognozi	Real vaqt virtual o‘lchov	Vaqtli testda belgilangan MAE/R^2 chegarasi
3. Advisory AI	Operatorga set-point tavsiyasi	Human-in-the-loop qaror jurnali	Tavsiya xavfsiz va takrorlanuvchi foyda beradi
4. Bounded control	Faqat ruxsat etilgan diapazonda avtomatik tuzatish	Yopiq siklli boshqaruv	Interlock, fallback va drift monitor ishlaydi
5. Continuous learning	Reconciliation va davriy retraining	Barqaror raqamli egizak	Model versiyasi va audit izi doimiy yuritiladi

XULOSA

Mazkur tadqiqotda foydali qazilmalarni maydalash va boyitish jarayonlarini sun’iy intellekt asosida optimallashtirish uchun integrallashgan IMRAD metodologiyasi ishlab chiqildi. Yondashuv maydalash, yanchish, klassifikatsiya va flotatsiyani yagona mine-to-concentrate qaror zanjirida bog‘laydi. Asosiy tamoyil — sensor ma’lumotlarini nolinear prognoz, ko‘p mezonli optimallashtirish, raqamli egizak va reconciliation bilan yopiq siklga birlashtirishdir.

Sintetik validatsiyada ansambl modellar chiziqli regressiyaga nisbatan yuqori prognoz aniqligini ko‘rsatdi; eng yaxshi algoritm maqsadga qarab farq qildi. Bu holat ishlab chiqarishda “bitta universal AI

© Ushbu material Creative Commons Attribution 4.0 International (CC BY 4.0) litsenziyasi asosida tarqatiladi.

modeli" o'rniga vazifa bo'yicha maxsus modellar portfelidan foydalanish maqsadga muvofiqligini ko'rsatadi. Illustrativ SI ssenariysida maxsus energiya va P80 yaxshilanishi bilan birga unumdorlik, flotatsiya recovery va konsentrat grade ni birgalikda boshqarish mumkinligi namoyish etildi. Barcha sonli natijalar metodik simulyatsiya bo'lib, real sanoat kafolati sifatida talqin qilinmaydi.

Kelgusida metodologiyani real boyitish fabrikasining tarixiy va onlayn ma'lumotlari bilan tekshirish, vaqt va ruda zonalari bo'yicha cross-validation o'tkazish, SHAP/XAI orqali tavsiyalarni izohlash, fizik cheklovli hybrid modellarni joriy etish hamda operator ishonchi va iqtisodiy samaradorlikni birgalikda baholash zarur. Sanoat joriy etilishi bosqichma-bosqich: ma'lumotlarni tozalash → soft-sensor → advisory mode → bounded closed-loop control → doimiy model drift nazorati ketma-ketligida olib borilishi tavsiya etiladi.

FOYDALANILGAN ADABIYOTLAR

1. McCoy, J. T., & Auret, L. (2019). Machine learning applications in minerals processing: A review. Minerals Engineering, 132, 95–109. https://doi.org/10.1016/j.mineng.2018.12.004
2. Gomez-Flores, A., Ilyas, S., Heyes, G. W., & Kim, H. (2022). A critical review of artificial intelligence in mineral concentration. Minerals Engineering, 189, 107884. https://doi.org/10.1016/j.mineng.2022.107884
3. Saldaña, M., Gálvez, E., Navarra, A., Toro, N., & Cisternas, L. A. (2023). Optimization of the SAG Grinding Process Using Statistical Analysis and Machine Learning: A Case Study of the Chilean Copper Mining Industry. Materials, 16(8), 3220. https://doi.org/10.3390/ma16083220
4. Ghasemi, Z., Neumann, F., Zanin, M., Karageorgos, J., & Chen, L. (2024). A comparative study of prediction methods for semi-autogenous grinding mill throughput. Minerals Engineering, 205, 108458. https://doi.org/10.1016/j.mineng.2023.108458
5. Ghasemi, Z., Neshat, M., Aldrich, C., Karageorgos, J., Zanin, M., Neumann, F., & Chen, L. (2024). An integrated intelligent framework for maximising SAG mill throughput: Incorporating expert knowledge, machine learning and evolutionary algorithms for parameter optimisation. Minerals Engineering, 212, 108733. https://doi.org/10.1016/j.mineng.2024.108733
6. Ghasemi, Z., Neshat, M., Aldrich, C., Zanin, M., & Chen, L. (2025). Optimising SAG mill throughput and circulating load using machine learning models: A multi-objective approach for identifying optimal process parameters. Minerals Engineering, 232, 109551. https://doi.org/10.1016/j.mineng.2025.109551
7. Jo, K., Je, J., Lee, D., Cho, H., Kim, K., & You, K. (2024). Prediction of multi-stage froth flotation efficiency of complex lead–zinc sulfide ore using an integrated ensemble neural network–random forest model. Minerals Engineering, 210, 108669. https://doi.org/10.1016/j.mineng.2024.108669
8. Aldrich, C., Avelar, E., & Liu, X. (2022). Recent advances in flotation froth image analysis. Minerals Engineering, 188, 107823. https://doi.org/10.1016/j.mineng.2022.107823
9. Pu, Y., Szmigiel, A., Chen, J., & Apel, D. B. (2020). FlotationNet: A hierarchical deep learning network for froth flotation recovery prediction. Powder Technology, 375, 317–326. https://doi.org/10.1016/j.powtec.2020.07.102
10. Ohenoja, M., Koistinen, A., Hultgren, M., Remes, A., Kortelainen, J., Kaartinen, J., Peltoniemi, M., & Ruusunen, M. (2023). Continuous adaptation of a digital twin model for a pilot flotation plant. Minerals Engineering, 198, 108081. https://doi.org/10.1016/j.mineng.2023.108081
11. Nasiri Abarbekouh, M., Iqbal, S., & Särkkä, S. (2025). Physics-informed machine learning for grade prediction in froth flotation. Minerals Engineering, 227, 109297. https://doi.org/10.1016/j.mineng.2025.109297

© Ushbu material Creative Commons Attribution 4.0 International (CC BY 4.0) litsenziyasi asosida tarqatiladi.

12. Hasidi, O., Abdelwahed, E. H., El Alaoui-Chrifi, M. A., Chahid, R., Qazdar, A., Qassimi, S., Zaizi, F. Z., Bourzeix, F., Benzakour, I., & Bendaouia, A. (2024). Data-driven system for intelligent monitoring and optimization of froth flotation circuits using Artificial Neural Networks and Genetic Algorithms. Journal of Process Control, 137, 103198. https://doi.org/10.1016/j.jprocont.2024.103198
13. Koh, E. J. Y., Amini, E., Gaur, S., Becerra Maquieira, M., Jara Heck, C., McLachlan, G. J., & Beaton, N. (2022). An Automated Machine Learning (AutoML) approach to regression models in minerals processing with case studies of developing industrial comminution and flotation models. Minerals Engineering, 189, 107886. https://doi.org/10.1016/j.mineng.2022.107886
14. Fu, Y., & Aldrich, C. (2023). Online particle size analysis on conveyor belts with dense convolutional neural networks. Minerals Engineering, 193, 108019. https://doi.org/10.1016/j.mineng.2023.108019
15. Bendaouia, A., Abdelwahed, E. H., Qassimi, S., Boussetta, A., Benzakour, I., Amar, O., & Hasidi, O. (2024). Artificial intelligence for enhanced flotation monitoring in the mining industry: A ConvLSTM-based approach. Computers & Chemical Engineering, 180, 108476. https://doi.org/10.1016/j.compchemeng.2023.108476

© Ushbu material Creative Commons Attribution 4.0 International (CC BY 4.0) litsenziyasi asosida tarqatiladi.