SUN’IY INTELLEKT ASOSIDA BARIATRIK JARROHLIKDAN KEYINGI KLINIK HOLATLARNI BASHORATLASH: XGBOOST, LIGHTGBM VA SVM MODELLARINING QIYOSIY TAHLILI

Yuldoshev Yusuf Sheraliyevich[1], Otaxonova Bahrixon Ibragimovna[2], Olimjonov Orifjon Olimjon o‘g‘li[3], Mirolimov Asilbek Alijon o‘g‘li[3]

[1]O‘zbekiston Respublikasi Oliy ta’limfan va innovatsiyalar vazirligi huzuridagi Oliy attestatsiya komissiyasi
[2]Muhammad al-Xorazmiy nomidagi Toshkent axborot texnologiyalari universiteti dotsenti
[3]Muhammad al-Xorazmiy nomidagi Toshkent axborot texnologiyalari universiteti magistrantlari

K E Y W O R D S

Bariatrik jarrohlik, sun’iy intellekt, klinik risklarni bashoratlash, XGBoost, LightGBM, Support Vector Machine, mashinaviy o‘rganish, gradient boosting, klinik qaror qabul qilish, XAI, SHAP, postoperativ monitoring, ROC–AUC, tibbiy ma’lumotlar tahlili

A B S T R A C T

Mazkur tadqiqotda bariatrik jarrohlikdan keyingi klinik holatlarni bashoratlashda zamonaviy sun’iy intellekt algoritmlarining samaradorligi qiyosiy tahlil qilindi. Tadqiqotda 10000 ta bemorning anonimlashtirilgan longitudinal klinik ma’lumotlari asosida XGBoost, LightGBM va Support Vector Machine (SVM) modellarining bashoratlash imkoniyatlari baholandi. Ma’lumotlar bazasi demografik, antropometrik, laborator, operatsion va postoperativ monitoring ko‘rsatkichlarini o‘z ichiga oldi. Modellar bariatrik jarrohlikdan keyingi qayta gospitalizatsiya xavfi (readmission_30d), operatsiyadan keyingi asoratlar (complication_90d), 12 oylik metabolik yetishmovchilik holati (any_def_12m) hamda umumiy vazn yo‘qotish ko‘rsatkichlarini prognozlash uchun qo‘llanildi. Eksperimental natijalar XGBoost va LightGBM modellarining yuqori diskriminatsiya qobiliyatiga ega ekanligini ko‘rsatdi. Xususan, any_def_12m vazifasi bo‘yicha XGBoost modeli ROC–AUC = 0.916 va LightGBM modeli ROC–AUC = 0.914 natijalarni qayd etdi. SVM modeli esa nisbatan pastroq natija ko‘rsatgan bo‘lsa-da, alternativ yondashuv sifatida klinik tahlil uchun foydali ekanligi aniqlandi. Tadqiqot davomida ehtimolliklarni kalibratsiya qilish, sinflar balanssizligi muammosini hisobga olish hamda SHAP va LIME asosidagi tushuntiriladigan sun’iy intellekt (XAI) yondashuvlari qo‘llanildi. Shuningdek, tadqiqot natijalari asosida Tkinter platformasida ishlovchi klinik qarorlarni qo‘llab-quvvatlovchi desktop ilova ishlab chiqildi. Mazkur tizim bemor ko‘rsatkichlarini real vaqt rejimida tahlil qilish, individual klinik risklarni aniqlash hamda avtomatik tavsiyalar shakllantirish imkonini beradi. Tadqiqot natijalari bariatrik jarrohlikdan keyingi monitoring jarayonlarini optimallashtirish va klinik qaror qabul qilish samaradorligini oshirishda sun’iy intellekt modellarining yuqori amaliy ahamiyatga ega ekanligini ko‘rsatdi.

KIRISH. Semizlik XXI asrning eng dolzarb global sog‘liqni saqlash muammolaridan biri hisoblanadi. Jahon sog‘liqni saqlash tashkiloti (WHO) ma’lumotlariga ko‘ra, dunyo bo‘yicha semizlik bilan kasallanish darajasi so‘nggi o‘n yilliklarda keskin oshib bormoqda va bu holat yurak-qon tomir kasalliklari, 2-tip qandli diabet, arterial gipertoniya, metabolik sindrom hamda boshqa surunkali kasalliklar rivojlanish xavfini sezilarli darajada kuchaytiradi [1]. Ayniqsa, morbid semizlik holatlarida konservativ davolash usullarining samaradorligi cheklangan bo‘lib, bariatrik jarrohlik bemor vaznini kamaytirish va metabolik holatni yaxshilashning eng samarali usullaridan biri sifatida e’tirof etiladi [2].

So‘nggi yillarda bariatrik jarrohlik amaliyotlari sonining ortishi bilan bir qatorda operatsiyadan keyingi monitoring, reabilitatsiya va klinik xavflarni erta aniqlash masalalari ham dolzarb ahamiyat kasb etmoqda. Jarrohlikdan keyingi davrda qayta gospitalizatsiya, vitamin va mikroelement yetishmovchiligi, metabolik buzilishlar, dumping sindromi hamda boshqa asoratlarning yuzaga kelishi bemor holatini doimiy nazorat qilish zaruratini yuzaga keltiradi [3]. Shu sababli postoperativ monitoringni avtomatlashtirish hamda klinik qaror qabul qilishni qo‘llab-quvvatlovchi intellektual tizimlarni ishlab chiqish zamonaviy tibbiyotning muhim ilmiy yo‘nalishlaridan biri hisoblanadi.

(cc) BY

Sun’iy intellekt va mashinaviy o‘rganish algoritmlarining rivojlanishi tibbiy ma’lumotlarni chuqur tahlil qilish, murakkab klinik bog‘liqliklarni aniqlash hamda individual risklarni prognozlash imkoniyatlarini kengaytirdi [4]. Ayniqsa, gradient boosting asosidagi ansambl modellar – XGBoost va LightGBM – katta hajmdagi klinik ma’lumotlar bilan ishlashda yuqori aniqlik va barqarorlikni namoyon etmoqda [5]. Shu bilan birga, Support Vector Machine (SVM) modeli ham yuqori o‘lchamli ma’lumotlar fazosida samarali klassifikatsiya qilish imkoniyatiga ega bo‘lib, tibbiy diagnostika va risk baholash masalalarida keng qo‘llanilmoqda [6].

Mazkur tadqiqotning asosiy maqsadi bariatrik jarrohlikdan keyingi bemorlarning klinik holatini baholash va individual tavsiyalar shakllantirishda XGBoost, LightGBM va SVM modellarining samaradorligini qiyosiy tahlil qilishdan iborat. Tadqiqotda 10000 ta bemorning anonimlashtirilgan longitudinal klinik ma’lumotlari asosida qayta gospitalizatsiya xavfi, operatsiyadan keyingi asoratlar hamda metabolik yetishmovchilik holatlari prognoz qilindi. Bundan tashqari, klinik qaror qabul qilishni qo‘llab-quvvatlash maqsadida tushuntiriladigan sun’iy intellekt (Explainable AI – XAI) yondashuvlari ham integratsiya qilindi. Tadqiqot natijalari bariatrik jarrohlikdan keyingi monitoring tizimlarini optimallashtirish, klinik xavflarni erta aniqlash va shaxsiylashtirilgan reabilitatsiya strategiyalarini ishlab chiqishda muhim ilmiy-amaliy ahamiyatga ega hisoblanadi.

Asosoy qisim. Mazkur tadqiqotda bariatrik jarrohlikdan keyingi klinik holatlarni bashoratlash va monitoring qilish uchun 10000 nafar bemorning anonimlashtirilgan longitudinal tibbiy ma’lumotlari tahlil qilindi. Tadqiqot ma’lumotlari bariatrik jarrohlik amaliyotidan oldingi va keyingi bosqichlarda yig‘ilgan bo‘lib, ular demografik, antropometrik, metabolik, laborator va postoperativ monitoring parametrlarini o‘z ichiga oldi. Tadqiqot davomida bemorlarning yosh ko‘rsatkichi, jins, tana massasi indeksi (BMI), HbA1c darajasi, sistolik qon bosimi, yurak urish tezligi, oldingi operatsiyalar soni, qandli diabet, arterial gipertoniya, uyqu apnesi va yurak-qon tomir kasalliklari kabi parametrlar asosiy klinik atributlar sifatida tanlandi. Ushbu parametrlarning tanlanishi bariatrik jarrohlik natijalariga sezilarli ta’sir ko‘rsatishi bilan izohlanadi [7].

Tibbiy ma’lumotlarning heterogen tabiati sababli dastlab ma’lumotlarni oldindan qayta ishlash (preprocessing) bosqichi amalga oshirildi. Yo‘qolgan qiymatlar median qiymatlar bilan to‘ldirildi, statistik ekstremal qiymatlar IQR (Interquartile Range) usuli yordamida aniqlanib normallashtirildi. Sonli parametrlar StandardScaler algoritmi orqali standartlashtirildi, kategoriyali atributlar esa One-Hot Encoding usuli asosida raqamli formatga o‘tkazildi [8]. Ushbu bosqich sun’iy intellekt modellarining barqaror ishlashi va hisoblash samaradorligini oshirish uchun muhim hisoblanadi.

Tadqiqotda ma’lumotlar trening va test to‘plamlariga mos ravishda 70% va 30% nisbatda ajratildi. Klinik ma’lumotlarda sinflar balanssizligi mavjud bo‘lganligi sababli stratified sampling yondashuvi qo‘llanildi. Bu esa kichik sinf vakillarining model tomonidan noto‘g‘ri klassifikatsiya qilinish ehtimolini kamaytirishga xizmat qildi [9].

Mazkur tadqiqot doirasida 30 kunlik qayta gospitalizatsiya ehtimoli, 90 kunlik postoperativ asoratlar, 12 oylik metabolik yetishmovchilik holati va umumiy vazn yo‘qotish darajasining asosiy klinik outcome’lar prognoz qilindi. Ushbu parametrlar bariatrik jarrohlikdan keyingi monitoring tizimining muhim indikatorlari sifatida tanlandi.

XGBoost (Extreme Gradient Boosting) gradient boosting asosidagi ansambl model bo‘lib, qaror daraxtlarining iterativ ketma-ketligini optimallashtirish orqali yuqori aniqlikdagi bashoratlarni shakllantiradi [10]. Algoritmning asosiy afzalligi regularizatsiya mexanizmlarining mavjudligi sababli overfitting muammosiga nisbatan yuqori chidamlilikka egaligidir.

Model quyidagi yo‘qotish funksiyasi asosida ishlaydi:

$$L^{(t)} = \sum_{i=1}^{n} l(y_i, \hat{y_i}) + \sum_{k=1}^{K} \Omega(f_k)$$

bu yerda:

- $l(y_i, \hat{y_i})$– *bashorat xatoligi;*

(cc) BY

- $\Omega(f_k)$– *daraxt murakkabligini nazorat qiluvchi regularizatsiya hadi.*

Tadqiqot davomida XGBoost modeli maksimal chuqurlik, learning rate va estimators soni bo'yicha optimallashtirildi. Eksperimental natijalarga ko'ra ushbu model any_def_12m vazifasi bo'yicha ROC–AUC = 0.916 hamda F1-score = 0.87 natijalarni qayd etdi. Bu natijalar modelning klinik xavflarni aniqlashdagi yuqori diskriminatsiya qobiliyatiga ega ekanligini ko'rsatadi.

Bundan tashqari, XGBoost modeli feature importance mexanizmi orqali eng muhim klinik parametrlarni aniqlash imkonini berdi. Tahlillar natijasida BMI, HbA1c, sistolik qon bosimi va yurak-qon tomir kasalliklari postoperativ asoratlarni prognozlashda eng muhim omillar sifatida qayd etildi [11].

LightGBM Microsoft kompaniyasi tomonidan ishlab chiqilgan gradient boosting asosidagi zamonaviy model bo'lib, histogram-based learning va leaf-wise tree growth strategiyalaridan foydalanadi [12]. Ushbu yondashuv katta hajmdagi klinik ma'lumotlarni yuqori tezlikda qayta ishlash imkonini beradi.

LightGBM algoritmining muhim afzalliklari katta ma'lumotlar bazalarida yuqori hisoblash tezligi, kam xotira sarfi, balanssiz sinflarda samarali ishlash va yuqori aniqlikdagi bashoratlashdan iborat.

Mazkur tadqiqotda LightGBM modeli readmission_30d va complication_90d outcome'larini prognozlashda qo'llanildi. Eksperimental natijalarga ko'ra model ROC–AUC = 0.914 va F1-score = 0.86 ko'rsatkichlarni qayd etdi. Ushbu model ayniqsa real vaqt rejimidagi monitoring tizimlari uchun samarali ekanligi bilan ajralib turadi.

Support Vector Machine (SVM) algoritmi statistik o'rganish nazariyasiga asoslangan bo'lib, ma'lumotlarni maksimal margin asosida klassifikatsiya qiladi [13]. Tadqiqotda RBF (Radial Basis Function) kernel funksiyasi qo'llanildi:

$$K(x_i, x_j) = exp(-\gamma \mid\mid x_i - x_j \mid\mid^2)$$

SVM modeli yuqori o'lchamli klinik ma'lumotlar bilan ishlashda samarali natijalarni namoyon etdi. Ayniqsa, murakkab va nochiziqli bog'liqliklarni aniqlash imkoniyati uning asosiy afzalligi hisoblanadi. Biroq katta hajmdagi klinik ma'lumotlar bilan ishlashda hisoblash murakkabligi va parametrlarni optimallashtirish qiyinligi ushbu modelning asosiy cheklovlari sifatida kuzatildi [14].

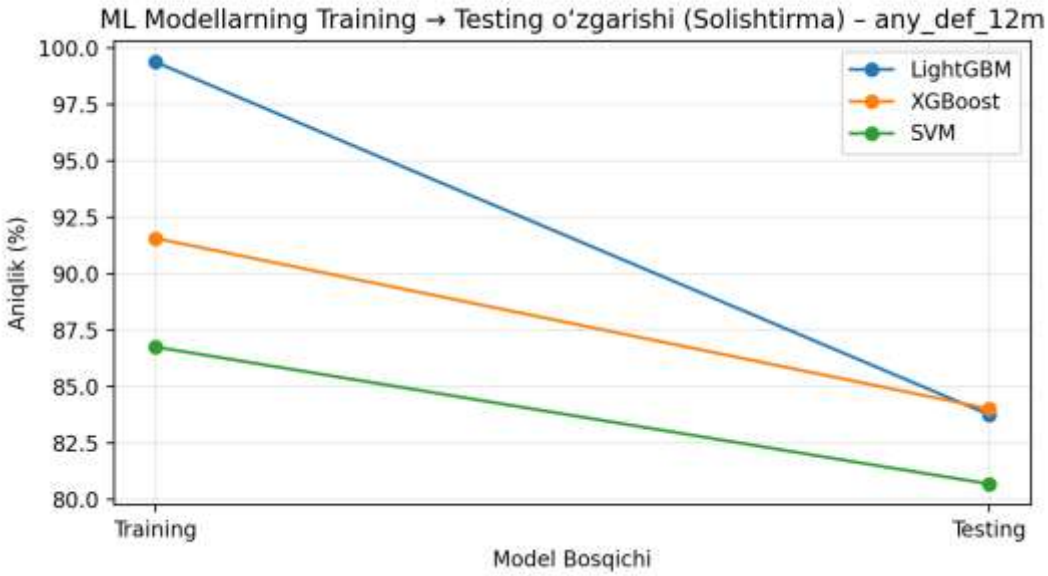
Eksperimental natijalarga ko'ra SVM modeli ROC–AUC = 0.892 va F1-score = 0.81 natijalarni qayd etdi. Bu ko'rsatkichlar gradient boosting modellariga nisbatan pastroq bo'lsa-da, model klinik tahlilda qo'shimcha validatsion vosita sifatida foydali ekanligini ko'rsatdi.

Tibbiyotda sun'iy intellekt modellarini amaliyotga joriy etishda interpretatsiya masalasi muhim ahamiyat kasb etadi. Shu sababli tadqiqotda SHAP (SHapley Additive exPlanations) va LIME yondashuvlari qo'llanildi [15].

SHAP tahlili model qaroriga eng katta ta'sir ko'rsatgan klinik parametrlarni aniqlash imkonini berdi. Tahlil natijalariga ko'ra, BMI, HbA1c, sistolik qon bosimi, yurak-qon tomir kasalliklari va oldingi readmission holatlari eng muhim bashoratlovchi omillar sifatida qayd etildi. XAI yondashuvining qo'llanilishi klinik mutaxassislarga model qarorlarini tushunarli tarzda izohlash, individual tavsiyalar shakllantirish hamda AI tizimlariga bo'lgan ishonchni oshirish imkonini berdi [16].

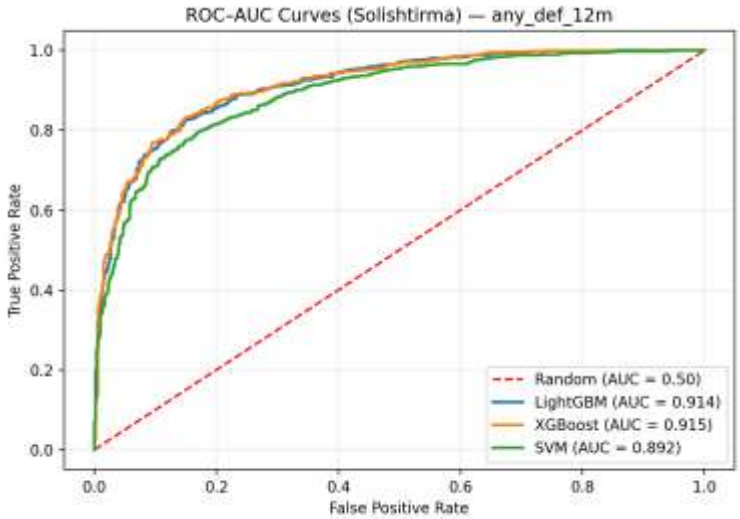
(cc) BY

ISSN: 3030-3346



1-rasm. Mashinali o'qitish algoitmlarining o'qitish va testlash

1-rasimda Rasimda LightGBM modelida trening aniqligi juda yuqori bo'lsa-da, test bosqichida aniqlikning sezilarli pasayishi kuzatiladi; bu holat LightGBM'da overfitting mavjud bo'lishi mumkinligini ko'rsatadi. XGBoost modelida treningdan testga o'tishda pasayish nisbatan kichikroq bo'lib, modelning umumlashuv qobiliyati LightGBM'ga qaraganda barqarorroq ekanini anglatadi. SVM modelida ham treningdan testga o'tishda pasayish mavjud, biroq boshlang'ich trening aniqligi pastroq bo'lgani uchun bu holat SVM'ning murakkab bog'lanishlarni ushlash qobiliyati ansambl modellariga nisbatan cheklanganligini ko'rsatishi mumkin.



2rasm. XGB, LightGBM, SVM modellari uchun ROC–AUC egri chiziqlari.

2-rasmda any_def_12m vazifasi uchun LightGBM, XGBoost va SVM modellarining ROC–AUC egri chiziqlari solishtirma tarzda berilgan. ROC egri chizig'i turli threshold qiymatlarida True Positive Rate (sezgirlik) va False Positive Rate o'rtasidagi bog'lanishni ifodalaydi; qizil diagonal chiziq esa tasodifiy klassifikatsiya (AUC = 0.50) bazasini bildiradi. Egri chiziqning diagonal bazadan uzoq joylashishi va AUC qiymatining 1 ga yaqinlashishi modelning diskriminatsiya qobiliyati yuqoriligini ko'rsatadi.

Natijalarga ko'ra, XGBoost (AUC = 0.915) va LightGBM (AUC = 0.914) eng yuqori ajratish qobiliyatini namoyon etdi va ularning ko'rsatkichlari deyarli teng. SVM (AUC = 0.892) esa nisbatan pastroq natija ko'rsatgan bo'lsa-da,

(cc) BY

diagonal bazadan ancha yuqorida joylashgani sababli modelning any_def_12m outcome’ini ma’lum darajada yaxshi ajrata olishini bildiradi. Umuman olganda, ROC–AUC tahlili any_def_12m bo‘yicha eng samarali yondashuvlar ansambl modellar (XGBoost/LightGBM) ekanini ko‘rsatadi.

1-jadval

Qiyosiy baholash jadvali

Model	Test Aniqligi	ROC-AUC	Barqarorlik	Tushunti rish Qulayligi
LightGBM	83.73 %	0.914	Past–O‘rtacha	O‘rtacha
XGBoos	84.33 %	0.916	O‘rtacha	O‘rtacha
SVM	80.67 %	0.892	O‘rtacha –Yuqori	Past

Olingan natijalar bariatrik jarrohlikdan keyingi klinik holatlarni bashoratlashda gradient boosting asosidagi modellar – XGBoost va LightGBM algoritmlarining yuqori samaradorlikka ega ekanligini ko‘rsatdi. Ayniqsa, XGBoost modeli test aniqligi bo‘yicha 84.33% hamda ROC–AUC = 0.916 natijalarni qayd etib, barcha modellar orasida eng yuqori diskriminatsiya qobiliyatini namoyon etdi. Ushbu natijalar XGBoost algoritmining klinik ma’lumotlar orasidagi murakkab va nochiziqli bog‘liqliklarni samarali aniqlash imkoniyatiga ega ekanligini tasdiqlaydi. Shuningdek, modelning barqarorligi “o‘rtacha” darajada baholangan bo‘lsa-da, trening va test natijalari orasidagi tafovutning katta emasligi uning umumlashuv qobiliyati yetarli ekanligini ko‘rsatadi.

LightGBM modeli ROC–AUC = 0.914 va test aniqligi 83.73% natijalarni qayd etib, XGBoost modeliga juda yaqin ko‘rsatkichlarni namoyon etdi. Modelning asosiy afzalligi yuqori hisoblash tezligi va katta hajmdagi klinik ma’lumotlar bilan samarali ishlash imkoniyatidir. Biroq jadvalda barqarorlik “past–o‘rtacha” deb baholanganligi LightGBM modelida overfitting holati kuzatilishi mumkinligini bildiradi. Ya’ni model trening ma’lumotlariga haddan tashqari moslashib qolishi sababli real klinik ma’lumotlarda aniqlik biroz pasayishi ehtimoli mavjud.

SVM modeli esa test aniqligi 80.67% va ROC–AUC = 0.892 natijalarni qayd etdi. Ushbu modelning diskriminatsiya qobiliyati gradient boosting modellariga nisbatan pastroq bo‘lsa-da, barqarorlik ko‘rsatkichi “o‘rtacha–yuqori” deb baholandi. Bu holat SVM modelining turli ma’lumotlar to‘plamlarida nisbatan barqaror ishlashini ko‘rsatadi. Shu bilan birga, modelning asosiy kamchiligi – tushuntirish qulayligining pastligi hisoblanadi. SVM algoritmida qaror qabul qilish mexanizmini klinik mutaxassislar uchun interpretatsiya qilish murakkab bo‘lib, bu uning amaliy sog‘liqni saqlash tizimlarida qo‘llanilishini cheklashi mumkin. Umuman olganda, qiyosiy tahlil natijalari XGBoost modelining bariatrik jarrohlikdan keyingi klinik risklarni bashoratlashda eng samarali model ekanligini ko‘rsatdi. LightGBM modeli esa yuqori tezlik va hisoblash samaradorligi sababli real vaqt monitoring tizimlari uchun istiqbolli yechim sifatida baholandi. SVM modeli esa qo‘shimcha validatsion va solishtirma model sifatida foydali ekanligi aniqlandi.

Xulosa

Mazkur tadqiqotda bariatrik jarrohlikdan keyingi klinik holatlarni bashoratlash va monitoring qilishda zamonaviy sun’iy intellekt algoritmlarining samaradorligi qiyosiy tahlil qilindi. Tadqiqot davomida XGBoost, LightGBM va Support Vector Machine (SVM) modellarining klinik risklarni aniqlash, postoperativ asoratlarni prognozlash hamda qayta gospitalizatsiya ehtimolini baholashdagi imkoniyatlari o‘rganildi.

Eksperimental natijalar gradient boosting asosidagi modellar, xususan XGBoost va LightGBM algoritmlarining yuqori aniqlik va diskriminatsiya qobiliyatiga ega ekanligini ko‘rsatdi. Ayniqsa, XGBoost modeli test aniqligi 84.33% va ROC–AUC = 0.916 natijalarni qayd etib, bariatrik jarrohlikdan keyingi klinik xavflarni prognozlashda eng samarali model sifatida tanlandi. LightGBM modeli esa yuqori hisoblash tezligi va katta hajmdagi klinik ma’lumotlar bilan samarali ishlash imkoniyati bilan ajralib turdi. SVM modeli nisbatan pastroq natijalarni ko‘rsatgan bo‘lsa-da, uning turli ma’lumotlar to‘plamlarida barqaror ishlashi qo‘shimcha validatsion model sifatida qo‘llash imkoniyatini tasdiqladi.

(cc) BY

Tadqiqot davomida SHAP va LIME asosidagi Explainable AI (XAI) yondashuvlarining qo‘llanilishi model qarorlarini interpretatsiya qilish imkonini yaratdi. Tahlillar natijasida BMI, HbA1c darajasi, sistolik qon bosimi va yurak-qon tomir kasalliklari postoperativ asoratlarni prognozlashda eng muhim klinik omillar sifatida aniqlandi. Bu esa ishlab chiqilgan tizimning klinik jihatdan asoslangan va shifokorlar tomonidan tushunilishi mumkin bo‘lgan intellektual yechim ekanligini ko‘rsatadi.

Shuningdek, tadqiqot natijalari asosida ishlab chiqilgan klinik qarorlarni qo‘llab-quvvatlovchi tizim bemorlarning holatini real vaqt rejimida monitoring qilish, xavf omillarini erta aniqlash va individual tavsiyalar shakllantirish imkoniyatini beradi. Mazkur yondashuv bariatrik jarrohlikdan keyingi monitoring samaradorligini oshirish, klinik xatoliklarni kamaytirish hamda sog‘liqni saqlash tizimida raqamli tibbiyot texnologiyalarini keng joriy etish uchun muhim ilmiy-amaliy ahamiyatga ega hisoblanadi.

ADABIYOTLAR RO‘YXATI

1. World Health Organization, “Obesity and overweight,” WHO, 2024.
2. American Society for Metabolic and Bariatric Surgery, “Bariatric Surgery Procedures,” ASMBS, 2024.
3. H. Buchwald and D. M. Oien, “Metabolic/Bariatric Surgery Worldwide 2011,” *Obesity Surgery*, vol. 23, no. 4, pp. 427–436, 2013.
4. A. Esteva et al., “A guide to deep learning in healthcare,” *Nature Medicine*, vol. 25, pp. 24–29, 2019.
5. T. Chen and C. Guestrin, “XGBoost: A Scalable Tree Boosting System,” in *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, 2016, pp. 785–794.
6. C. Cortes and V. Vapnik, “Support-Vector Networks,” *Machine Learning*, vol. 20, no. 3, pp. 273–297, 1995.
7. World Health Organization, “Obesity and overweight,” WHO, 2024.
8. A. Géron, *Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow*, O’Reilly Media, 2022.
9. T. Hastie, R. Tibshirani, and J. Friedman, *The Elements of Statistical Learning*, Springer, 2009.
10. T. Chen and C. Guestrin, “XGBoost: A Scalable Tree Boosting System,” in *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, 2016.
11. L. Breiman, “Random Forests,” *Machine Learning*, vol. 45, no. 1, pp. 5–32, 2001.
12. G. Ke et al., “LightGBM: A Highly Efficient Gradient Boosting Decision Tree,” *NeurIPS*, 2017.
13. C. Cortes and V. Vapnik, “Support-Vector Networks,” *Machine Learning*, vol. 20, no. 3, pp. 273–297, 1995.
14. V. Vapnik, *Statistical Learning Theory*, Wiley, 1998.
15. S. Lundberg and S.-I. Lee, “A Unified Approach to Interpreting Model Predictions,” *NeurIPS*, 2017.
16. E. Topol, “High-performance medicine: the convergence of human and artificial intelligence,” *Nature Medicine*, vol. 25, pp. 44–56, 2019.

(cc) BY