ISSN: 3030-3346

OLIY TA’LIM MUASSASALARIDA PROFESSOR-O‘QITUVCHILARNING O‘QUV YUKLAMALARINI KO‘P MEZONLI OPTIMALLASHTIRISHNING MILP VA GENETIK ALGORITMGA ASOSLANGAN GIBRID MODELI

Saidova Fazilat Muzaffarovna[1], Saidov Samandar Muzaffarovich[2]

[1]Toshkent Amaliy fanlar assistenti
[2]Muhammad al-Xorazmiy nomidagi TATU dotsenti
E-mail: Sfazilat@bk.ru samandarsaidov.uz@gmail.uz

K E Y W O R D S

professor-o‘qituvchi yuklamasi, oliy ta’lim, Mixed-Integer Linear Programming, MILP, genetik algoritm, ko‘p mezonli optimallashtirish, constraint programming, yuklama balansi, optimallashtirish modeli, qarorlarni qo‘llab-quvvatlash tizimi

A B S T R A C T

Oliy ta’lim muassasalarida professor-o‘qituvchilarning o‘quv yuklamalarini samarali va muvozanatli taqsimlash ko‘plab cheklovlar, o‘qituvchi–fan mosligi, o‘quv guruhlari soni va mavjud yuklamalarni bir vaqtning o‘zida hisobga olishni talab qiladigan murakkab optimallashtirish masalasidir. Ushbu tadqiqotda professor-o‘qituvchilarning o‘quv yuklamalarini ko‘p mezonli optimallashtirishga mo‘ljallangan gibrid model taklif etiladi. Model constraint-based filtering, Mixed-Integer Linear Programming (MILP), multi-objective optimization va Genetic Algorithm (GA) usullarining integratsiyasiga asoslangan. Dastlab, qat’iy o‘quv jarayoni cheklovlariga mos kelmaydigan taqsimot variantlari chiqarib tashlanadi. Keyingi bosqichda MILP yordamida optimal yoki unga yaqin optimal yechim aniqlanadi va o‘qituvchi–fan mosligi, yuklama balansi hamda oldingi davrga nisbatan o‘zgarish darajasi birgalikda optimallashtiriladi. Katta hajmdagi masalalarda GA qidiruv jarayonining samaradorligini oshirish uchun qo‘llaniladi. Taklif etilayotgan model yuklamalarni avtomatik, muvozanatli va cheklovlarga mos ravishda shakllantirish imkonini beradi. Modelning amaliy samaradorligini universitet o‘quv yuklamalarini boshqarish axborot tizimi ma’lumotlari asosida baholash rejalashtirilgan.

Kirish. Oliy ta’lim muassasalarida o‘quv jarayonini samarali tashkil etish professor-o‘qituvchilarning o‘quv yuklamalarini to‘g‘ri shakllantirish va taqsimlash bilan bevosita bog‘liq. O‘quv yuklamasining noto‘g‘ri taqsimlanishi ayrim professor-o‘qituvchilarda ortiqcha ish hajmining shakllanishiga, boshqalarida esa mavjud mehnat resurslaridan to‘liq foydalanilmasligiga olib kelishi mumkin. Yuklama taqsimoti masalasi bir vaqtning o‘zida bir nechta omillarni hisobga olishni talab qiladi. Jumladan, o‘qituvchining mutaxassisligi, akademik darajasi, fan bo‘yicha tajribasi, fan turi, akademik guruhlar soni, mashg‘ulot shakli, belgilangan minimal va maksimal yuklama hamda kafedraning umumiy o‘quv ehtiyoji shular jumlasidandir. Bu masala matematik nuqtai nazardan kombinatorik optimallashtirish masalasiga yaqin bo‘lib, o‘qituvchilar va fanlar soni ortishi bilan mumkin bo‘lgan yechimlar fazosi keskin kengayadi. Shu sababli oddiy qo‘lda taqsimlash yoki faqat deterministik qoidalar asosida ishlaydigan algoritmlar katta hajmdagi universitet ma’lumotlarini qayta ishlashda yetarli samaradorlikni ta’minlamasligi mumkin. Ushbu tadqiqotda mazkur muammoni hal qilish uchun bir nechta optimallashtirish yondashuvlarini birlashtiruvchi gibrid model taklif qilinadi. Tadqiqotning asosiy gipotezasi shundan iboratki, constraint-based filtering, MILP va metaheuristik qidiruvni birlashtirish professor-o‘qituvchilarning o‘quv yuklamalarini taqsimlashda yechim sifatini

(cc) BY *dtai.uz*

saqlagan holda hisoblash samaradorligini oshirishi mumkin.

Tadqiqotning asosiy maqsadi professor-o‘qituvchilarning o‘quv yuklamalarini o‘qituvchi fan mosligi, yuklama muvozanati va mavjud cheklovlarni hisobga olgan holda ko‘p mezonli optimallashtirish imkonini beruvchi gibrid matematik model va algoritm ishlab chiqish.

Taklif etilayotgan gibrid model to‘rtta o‘zaro bog‘langan bosqichdan tashkil topadi: Constraint Model, Mixed-Integer Linear Programming (MIP/MILP), Multi-objective Optimization va Genetic Algorithm (GA). Har bir bosqich optimallashtirish jarayonining muayyan vazifasini bajaradi va yakuniy yechimning feasibility, optimality, muvozanat va hisoblash samaradorligi ko‘rsatkichlarini yaxshilashga xizmat qiladi.

Constraint Model. Birinchi bosqichda optimallashtirish jarayoniga uzatiladigan yechimlar fazosi shakllantiriladi. Uning asosiy vazifasi o‘quv jarayonining qat’iy cheklovlarini qanoatlantirmaydigan o‘qituvchi–fan birikmalarini dastlabki bosqichda aniqlash va chiqarib tashlashdan iborat.

Bunda quyidagi cheklovlar hisobga olinadi:

- o‘qituvchining mutaxassisligi fan mazmuniga mosligi;
- o‘qituvchining tegishli fan bo‘yicha kompetensiyasi;
- o‘qituvchining mashg‘ulot turini olib borish imkoniyati;
- o‘qituvchining lavozimi va malaka talablariga muvofiqligi;
- o‘qituvchining mavjudligi;
- fan va akademik guruhning ta’lim shakliga mosligi;
- o‘quv jarayonining boshqa tashkiliy cheklovlari.

Dastlab barcha nazariy mumkin bo‘lgan taqsimot variantlari to‘plami (S) bilan belgilanadi. Har bir qat’iy cheklov $C_k(s)$ orqalii ifodalanadi. Shunda feasible solution space quyidagicha aniqlanadi:

$$S' = \{s \in S \mid C_k(s) = 1, \quad k = 1, \ldots, m\}$$

bu yerda:

- S — *barcha nazariy mumkin bo‘lgan taqsimot variantlari to‘plami;*
- S' — *barcha qat’iy cheklovlarni qanoatlantiruvchi ruxsat etilgan yechimlar fazosi;*
- $C_k(s)$ — *s -yechimning k -cheklovni qanoatlantirish holatini bildiruvchi funksiya;*
- m — *hisobga olinadigan qat’iy cheklovlar soni.*

Natijada:

$$S' \subseteq S$$

munosabat hosil bo‘ladi. Bu bosqichning asosiy afzalligi shundaki, keyingi optimallashtirish algoritmlari kamaytirilgan va amaliy jihatdan maqbul yechimlar fazosida ishlaydi.

MIP/MILP ikkinchi bosqichda birinchi bosqichda shakllantirilgan ruxsat etilgan yechimlar fazosi asosida professor-o‘qituvchilarning o‘quv yuklamalarini matematik optimallashtirish amalga oshiriladi. Buning uchun Mixed-Integer Linear Programming modeli qo‘llaniladi. MILP yondashuvi o‘qituvchi–fan biriktirish, o‘quv faoliyatlarini taqsimlash hamda professor-o‘qituvchilarning minimal va maksimal yuklama chegaralarini qat’iy matematik cheklovlar orqali ifodalash imkonini beradi. Modelning asosiy qaror o‘zgaruvchisi quyidagicha aniqlanadi:

$$x_{ijgt} \in \{0,1\}$$

Har bir o‘quv faoliyatining aynan bitta professor-o‘qituvchiga biriktirilishini ta’minlash uchun quyidagi cheklov kiritiladi:

$$\sum_i x_{ijgt} = 1$$

Mazkur cheklov har bir fan–guruh–mashg‘ulot turi kombinatsiyasi faqat bitta o‘qituvchiga biriktirilishini kafolatlaydi.

(cc) BY

Professor-o‘qituvchining umumiy o‘quv yuklamasi L_i quyidagicha aniqlanadi:

$$L_i = \sum_j \sum_g \sum_t h_{jgt} x_{ijgt}$$

Har bir professor-o‘qituvchining yuklamasi belgilangan minimal va maksimal chegaralarda bo‘lishi kerak:

$$L_i^{min} \le L_i \le L_i^{max}$$

Tadqiqotd ushbu bosqichning asosiy vazifasi birinchi bosqichda feasible deb topilgan variantlar orasidan qat’iy matematik cheklovlarni qanoatlantiruvchi optimal yoki optimalga yaqin yuklama taqsimotini aniqlashdan iborat.

Multi-objective Optimization. Uchinchi bosqichda optimal taqsimot birgina mezon asosida emas, balki o‘zaro bog‘liq bir nechta sifat mezonlari asosida aniqlanadi. Professor-o‘qituvchilarning o‘quv yuklamalarini taqsimlash masalasida faqat umumiy soatlar miqdorini minimallashtirish yoki tenglashtirish yetarli emas. Taqsimotda o‘qituvchining tegishli fan bo‘yicha kompetensiyasi, professor-o‘qituvchilar o‘rtasidagi yuklama balansi hamda oldingi davrga nisbatan yuklama o‘zgarishining barqarorligi ham hisobga olinishi lozim. Mazkur tadqiqotda uchta asosiy maqsad funksiyasi shakllantiriladi:

1. o‘qituvchi–fan mosligini maksimal qilish;
2. professor-o‘qituvchilar yuklamalari o‘rtasidagi nomutanosiblikni minimallashtirish;
3. oldingi davrga nisbatan yuklama o‘zgarishini minimallashtirish.

Birinchi maqsad o‘qituvchining fan bo‘yicha kompetensiyasini hisobga olgan holda eng mos taqsimotni shakllantirishdan iborat.

$$\max F_1 = \sum_i \sum_j \sum_g \sum_t q_{ij} h_{jgt} x_{ijgt}$$

Ikkinchi maqsad professor-o‘qituvchilar o‘rtasida yuklamaning haddan tashqari notekis taqsimlanishining oldini olishdan iborat. Buning uchun har bir o‘qituvchining umumiy yuklamasi o‘rtacha yuklama o‘rtasidagi farq hisobga olinadi. Nomutanosiblik:

$$d_i \ge L_i - \bar{L}$$

$$d_i \ge \bar{L} - L_i$$

ko‘rinishida aniqlanadi. Shundan so‘ng ikkinchi maqsad funksiyasi quyidagicha ifodalanadi:

$$\min F_2 = \sum_i d_i$$

Bu funksiya professor-o‘qituvchilarning yuklamalari o‘rtasidagi umumiy tafovutni kamaytirishga xizmat qiladi.

Uchinchi maqsad taqsimotning davrlararo barqarorligini ta’minlashga qaratiladi. Bunda yangi davrdagi yuklama bilan oldingi davrdagi yuklama o‘rtasidagi farq hisobga olinadi. Yuklama o‘zgarishi:

$$\Delta_i = | L_i - L_i^{prev} |$$

ko‘rinishida aniqlanadi. Shunga mos ravishda uchinchi maqsad funksiyasi:

$$\min F_3 = \sum_i \Delta_i$$

ko‘rinishida ifodalanadi. Bu funksiya professor-o‘qituvchilarning oldingi davrdagi yuklamasiga nisbatan keskin o‘zgarishlarni kamaytirishga imkon beradi.

Ko‘p mezonli optimallashtirishning umumiy ko‘rinishi. Taklif etilayotgan modelda uchta maqsad bir vaqtning o‘zida hisobga olinadi:

$$\max F_1$$
$$\min F_2$$
$$\min F_3$$

Ushbu maqsadlarni yagona optimallashtirish modelida birlashtirish uchun og‘irlik

(cc) BY

ISSN: 3030-3346

koeffitsiyentlariga asoslangan yondashuvdan foydalanish mumkin:

$$\max F = w_1\hat{F}_1 - w_2\hat{F}_2 - w_3\hat{F}_3$$

bu yerda w_1, w_2, w_3 — tegishli mezonlarning ahamiyatini belgilovchi og‘irlik koeffitsiyentlari, $\hat{F}_1\hat{F}_2\hat{F}_3$ esa maqsad funksiyalarining normallashtirilgan qiymatlaridir. Og‘irlik koeffitsiyentlari quyidagi shartni qanoatlantiradi:

$$w_1 + w_2 + w_3 = 1$$

Natijada model professor-o‘qituvchilarning o‘quv yuklamalarini faqat soatlar miqdori asosida taqsimlash bilan cheklanmaydi. O‘qituvchi–fan mosligi, yuklama muvozanati va davrlararo barqarorlik yagona ko‘p mezonli optimallashtirish jarayonida birgalikda hisobga olinadi.

Genetic Algorithm. To‘rtinchi bosqichda katta o‘lchamli optimallashtirish masalalarini samarali yechish uchun **Genetic Algorithm (GA)** metaheuristik qidiruv mexanizmi sifatida qo‘llaniladi. Professor-o‘qituvchilar, fanlar, akademik guruhlar va mashg‘ulot turlari sonining ortishi bilan qaror o‘zgaruvchilari va mumkin bo‘lgan taqsimot kombinatsiyalari soni keskin oshadi. Natijada MILP modelining yechimni topish uchun talab qiladigan hisoblash vaqti ortishi mumkin. Shu sababli taklif etilayotgan gibrid model masala o‘lchamiga mos ravishda ikki xil ish rejimini nazarda tutadi. Kichik va o‘rta hajmdagi masalalarda MILP modeli asosiy optimallashtirish vositasi sifatida qo‘llaniladi. Katta hajmdagi masalalarda esa MILP tomonidan shakllantirilgan yechim yoki ruxsat etilgan yechimlar fazosi GA uchun boshlang‘ich qidiruv sohasi sifatida foydalanilib, metaheuristik qidiruv orqali yechimni takomillashtirish amalga oshiriladi.Modelning umumiy ishlash tamoyili quyidagicha ifodalanadi:

Small/Medium Problem → MILP

Large Problem → MILP + GA

GA doirasida har bir ehtimoliy yuklama taqsimoti individual (chromosome) sifatida ifodalanadi. Bir nechta individualdardan tashkil topgan to‘plam populationni hosil qiladi. Har bir individualning sifati yuqorida aniqlangan ko‘p mezonli maqsad funksiyalari asosida baholanadi.

GA algoritmining asosiy jarayoni quyidagi bosqichlardan iborat:

1. boshlang‘ich populationni shakllantirish;
2. har bir individual uchun fitness qiymatini hisoblash;
3. eng yaxshi individuallarni tanlash (selection);
4. yangi yechimlarni hosil qilish (crossover);
5. yechimlarda tasodifiy o‘zgarishlarni amalga oshirish (mutation);
6. qat’iy cheklovlarni buzuvchi yechimlarni tiklash yoki chiqarib tashlash (constraint repair);
7. yangi avlodni shakllantirish;
8. belgilangan to‘xtash shartiga erishilgunga qadar jarayonni takrorlash.

GA uchun fitness funksiyasi ko‘p mezonli optimallashtirish natijalariga asoslanadi va umumiy holda quyidagicha ifodalanishi mumkin:

$$Fitness = w_1F_1 - w_2F_2 - w_3F_3 - \lambda P$$

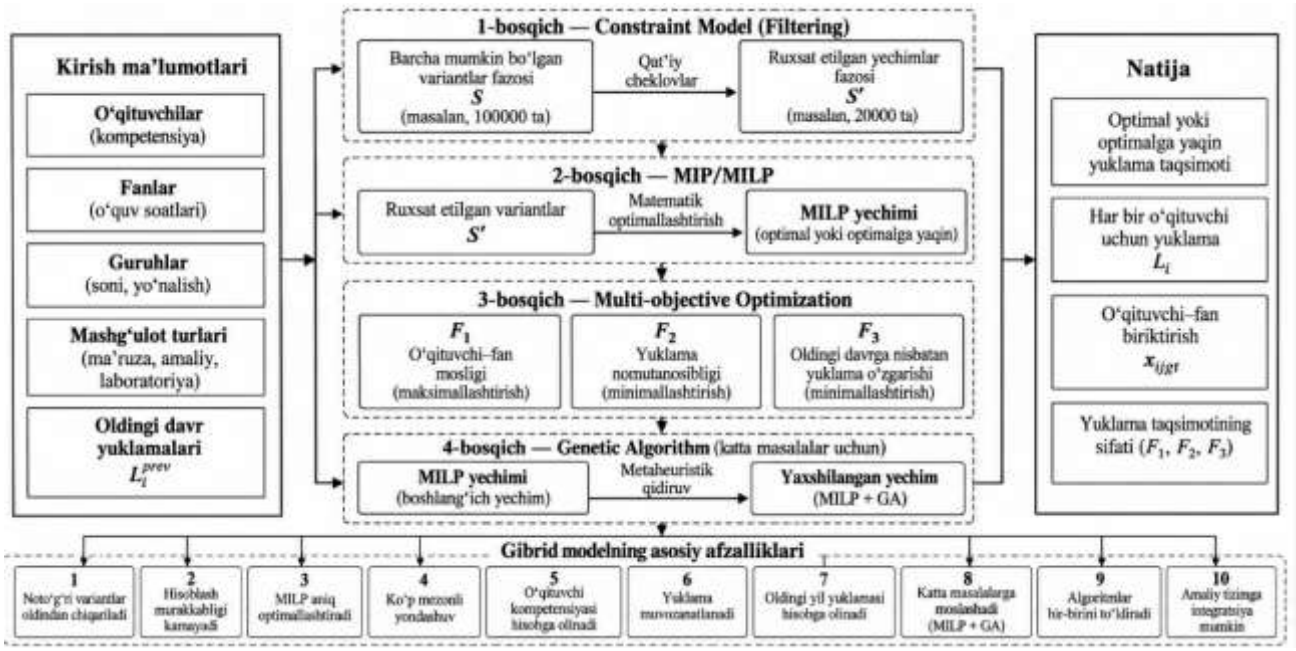
GA bosqichi katta hajmdagi yechimlar fazosida samarali qidiruvni tashkil etish va mavjud yechimlarni takomillashtirishga xizmat qiladi. Bunda GA mustaqil ravishda barcha qat’iy cheklovlarni tekshirishga majbur qilinmaydi; birinchi bosqichda shakllantirilgan feasible solution space va constraint-handling mexanizmi uning qidiruv jarayonini amaliy jihatdan maqbul yechimlar bilan chegaralaydi.

Taklif etilayotgan modelda kiruvchi ma’lumotlar professor-o‘qituvchilar tarkibi, fanlar, akademik guruhlar, mashg‘ulot turlari hamda oldingi davr o‘quv yuklamalaridan tashkil topadi. Ushbu ma’lumotlar optimallashtirish jarayonining barcha bosqichlarida yagona axborot bazasi sifatida foydalaniladi. Dastlab o‘qituvchilarning tegishli fanlarni o‘qitish kompetensiyasi, mashg‘ulot turiga mosligi va boshqa tashkiliy talablar tekshiriladi. Constraint-based filtering bosqichida amaliy jihatdan mumkin bo‘lmagan o‘qituvchi–fan

(cc) BY

kombinatsiyalari chiqarib tashlanadi. Natijada keyingi bosqichlarda foydalaniladigan ruxsat etilgan yechimlar fazosi shakllanadi. Ushbu jarayon optimallashtirish algoritmlarining keraksiz kombinatsiyalarni ko‘rib chiqishini kamaytirish orqali hisoblash samaradorligini oshirishga xizmat qiladi. Shakllantirilgan ruxsat etilgan yechimlar fazosi MIP/MILP modeliga uzatiladi. Ushbu bosqichda o‘quv faoliyatlarini professor-o‘qituvchilarga biriktirish, har bir o‘qituvchining minimal va maksimal yuklama chegaralarini ta’minlash hamda boshqa qat’iy cheklovlarni bajarish matematik model orqali amalga oshiriladi. Natijada optimal yoki optimalga yaqin yechim olinadi. Keyingi bosqichda hosil qilingan yechim uchta asosiy mezon bo‘yicha baholanadi: o‘qituvchi–fan mosligi, yuklama nomutanosibligi va oldingi davrga nisbatan yuklama o‘zgarishi. Ushbu mezonlarning birgalikda hisobga olinishi yakuniy taqsimotning sifat, muvozanat va barqarorlik ko‘rsatkichlarini yaxshilash imkonini beradi. Masala hajmi katta bo‘lgan hollarda yechimlar fazosining kengayishi sababli qo‘shimcha metaheuristik qidiruv mexanizmi talab etiladi. Bunday holatda Genetic Algorithm qo‘llanilib, MILP tomonidan olingan yechim boshlang‘ich yechim sifatida foydalaniladi. Genetik algoritm orqali yechimlar fazosida qo‘shimcha qidiruv amalga oshirilib, ko‘p mezonli baholash asosida yaxshilangan yechim shakllantiriladi.

Modelning yakuniy natijasi professor-o‘qituvchilar o‘rtasida fan va guruhlar kesimida taqsimlangan o‘quv yuklamalari, har bir o‘qituvchining umumiy yuklamasi hamda optimallashtirish mezonlari qiymatlaridan iborat bo‘ladi. Shu sababli taklif etilayotgan modelni universitetning o‘quv yuklamalarini boshqarish axborot tizimiga integratsiya qilish va yuklamalarni shakllantirish jarayonini avtomatlashtirish imkoniyati mavjud.



1-rasm. Professor-o‘qituvchilarning o‘quv yuklamalarini optimallashtirishga mo‘ljallangan gibrid modelning umumiy arxitekturasi.

1-rasmda ko‘rsatilganidek, taklif etilayotgan model ketma-ket va o‘zaro bog‘langan to‘rtta asosiy bosqichdan tashkil topadi. Birinchi bosqichda barcha nazariy mumkin bo‘lgan taqsimot variantlari qat’iy cheklovlar asosida filtrlanib, faqat ruxsat etilgan yechimlar fazosi S′ shakllantiriladi. Bu jarayon keyingi optimallashtirish bosqichlarida ko‘rib chiqiladigan yechimlar sonini kamaytirishga xizmat qiladi. Ikkinchi bosqichda hosil qilingan ruxsat etilgan yechimlar fazosi MIP/MILP modeliga uzatiladi. Ushbu bosqichda o‘qituvchi–fan biriktirish va professor-o‘qituvchilarning yuklama

(cc) BY *dtai.uz*

chegaralari matematik cheklovlar orqali hisobga olinadi.Uchinchi bosqichda taqsimot sifati uchta asosiy mezon — o‘qituvchi–fan mosligi F_1, yuklama nomutanosibligi F_2 va oldingi davrga nisbatan yuklama o‘zgarishi F_3 — bo‘yicha baholanadi. Mazkur mezonlarning birgalikda optimallashtirilishi yakuniy taqsimotning nafaqat matematik jihatdan mumkin, balki sifat va muvozanat nuqtayi nazaridan ham maqbul bo‘lishini ta’minlaydi. To‘rtinchi bosqichda masala o‘lchami katta bo‘lgan hollarda Genetic Algorithm qo‘llaniladi. Bunda MILP tomonidan olingan yechim boshlang‘ich yechim sifatida foydalanilib, genetik operatorlar yordamida yechimlar fazosida qo‘shimcha qidiruv amalga oshiriladi. Natijada optimal yoki optimalga yaqin yuklama taqsimoti shakllantiriladi va tizimning amaliy axborot tizimiga integratsiya qilinishi mumkin.

Taklif etilayotgan model universitetning o‘quv yuklamalarini boshqarish axborot tizimiga integratsiya qilinishi mumkin. Bunda ma’lumotlar bazasidan professor-o‘qituvchilar, fanlar, guruhlar, mashg‘ulot turlari va yuklama me’yorlari haqidagi ma’lumotlar olinadi. Keyingi bosqichda Constraint Engine ruxsat etilmagan variantlarni chiqaradi, MILP Solver optimal taqsimotni izlaydi, katta hajmdagi masalalarda esa GA Engine qidiruv jarayonini tezlashtiradi. Yakuniy natija mas’ul xodimga optimal yoki yaqin optimal yuklama taqsimoti sifatida taqdim etiladi.

Gibrid yondashuvning asosiy afzalligi har bir algoritmni o‘ziga mos vazifaga yo‘naltirishdan iborat. Constraint Model amaliy jihatdan mumkin bo‘lmagan yechimlarni chiqarib tashlaydi. MILP ruxsat etilgan yechimlar orasidan aniq matematik optimallashtirishni amalga oshiradi. Multi-objective yondashuv bir nechta sifat mezonlarini bir vaqtning o‘zida hisobga oladi. GA esa katta hajmdagi yechim fazosida qidiruvni samarali tashkil etish imkonini beradi.

Natijada gibrid model yechimning faqat mavjud bo‘lishini emas, balki uning sifatli, muvozanatli va amaliy jihatdan maqbul bo‘lishini ta’minlashga intiladi. Bunday yondashuv ayniqsa o‘qituvchilar, fanlar va guruhlar soni katta bo‘lgan oliy ta’lim muassasalarida dolzarb hisoblanadi.

Modelni amaliy tekshirish universitetning o‘quv yuklamalarini boshqarish axborot tizimi ma’lumotlari asosida amalga oshirilishi rejalashtirilgan. Bu bosqichda hisoblash vaqti, yuklama balansi, o‘qituvchi–fan mosligi va oldingi davr yuklamasidan og‘ish kabi ko‘rsatkichlarni baholash mumkin.

Xulosa

Tadqiqotda oliy ta’lim muassasalarida professor-o‘qituvchilarning o‘quv yuklamalarini ko‘p mezonli optimallashtirish masalasi ko‘rib chiqildi va Constraint Model, MILP, Multi-objective Optimization hamda Genetic Algorithm komponentlarini birlashtiruvchi gibrid model taklif etildi. Taklif etilgan yondashuvning birinchi bosqichida noto‘g‘ri va ruxsat etilmagan taqsimot variantlari chiqarib tashlanadi. Ikkinchi bosqichda MILP yordamida ruxsat etilgan yechimlar fazosidan optimal yoki unga yaqin optimal taqsimot izlanadi. Uchinchi bosqichda o‘qituvchi–fan mosligi, yuklama muvozanati va oldingi davrga nisbatan yuklama o‘zgarishi kabi mezonlar birgalikda hisobga olinadi. To‘rtinchi bosqichda esa katta hajmdagi masalalar uchun genetik algoritmdan foydalanish imkoniyati ko‘rsatiladi. Gibrid modelning asosiy afzalligi shundaki, u yuklamani oddiy soatlar taqsimoti sifatida emas, balki cheklovlar, o‘qituvchi kompetensiyasi, yuklama balansi va barqarorlikni hisobga oluvchi ko‘p mezonli optimallashtirish masalasi sifatida qaraydi. Constraint filtering yechimlar fazosini kamaytirib, keyingi optimallashtirish bosqichlarining hisoblash samaradorligini oshirishi mumkin. MILP va GA yondashuvlarining birlashtirilishi kichik va o‘rta hajmdagi masalalarda aniq matematik optimallashtirishdan, katta hajmdagi masalalarda esa metaheuristik qidiruvdan foydalanish imkonini beradi. Natijada taklif etilayotgan model oliy ta’lim muassasalarida o‘quv yuklamalarini avtomatlashtirilgan, muvozanatli va amaliy jihatdan maqbul tarzda taqsimlash uchun asos bo‘lib xizmat qilishi mumkin.

Foydalanilgan adabiyotlar ro‘yxati

1. Aggarwal C.C. Recommender Systems: The Textbook. – Springer, 2016. – 498 p.

(cc) BY

1. Mobasher B., Cooley R., Srivastava J. Automatic Personalization Based on Web Usage Mining // Communications of the ACM. – 2000. – Vol. 43(8). – P. 142–151.
2. Yang Y., Pedersen J.O. A Comparative Study on Feature Selection in Text Categorization // Proceedings of ICML. – 1997. – P. 412–420.
3. Zhang Y., Pennacchiotti M. Recommender Systems for Personalized Web Search // WWW Conference Proceedings. – 2013. – P. 1029–1038.
4. Wang J., Zhao Y. Clustering Algorithms in Web Usage Mining // Journal of Information Science. – 2014. – Vol. 40(2). – P. 199–213.
5. Yang J., Wu H. CLOPE: A Fast and Effective Clustering Algorithm for Transactional Data // Proceedings of ACM SIGKDD. – 2002. – P. 682–687.
6. Li X., Lin T.Y. Mining User Navigation Patterns for Web Personalization // Knowledge-Based Systems. – 2011. – Vol. 24(4). – P. 580–588.
7. Ricci F., Rokach L., Shapira B. Introduction to Recommender Systems Handbook. – Springer, 2015. – 870 p.
8. Burke R. Hybrid Recommender Systems: Survey and Experiments // User Modeling and User-Adapted Interaction. – 2002. – Vol. 12. – P. 331–370.
9. Saidov S.M., Jo‘rayev N.S. Shaxsga yo‘naltirilgan axborot tizimlarida foydalanuvchi profillarini shakllantirish // Zamonaviy axborot texnologiyalari. – Toshkent, 2022. – №3. – B. 45–52.
10. Mo‘minov B.B., Saidov S.M. Web resurslarda foydalanuvchi ehtiyojlarini klasterlash asosida aniqlash usullari // Actual Scientific Research in the Modern World. – 2023. – Issue 4(119). – P. 241–244.
11. O‘zbekiston Respublikasi Prezidentining qarori. “Raqamli iqtisodiyotni rivojlantirish strategiyasi”. – Toshkent, 2020.
12. ZiyoNET axborot-ta’lim portali. Shaxsga yo‘naltirilgan axborot tizimlari bo‘yicha elektron resurslar. https://www.ziyonet.uz
13. Google Scholar ilmiy ma’lumotlar bazasi. https://scholar.google.com

(cc) BY *dtai.uz*