

УДК 691.32:620.17:004.85

## О.С. Приходько

к.т.н., доцент, ORCID: <https://orcid.org/0000-0001-8496-1295>

Кафедра прикладної математики та механіки

Луцький національний технічний університет, вул. Львівська, 75, Луцьк, Україна, 43018

## В.О. Приходько

студент ПРМ-11

Луцький національний технічний університет, вул. Львівська, 75, Луцьк, Україна, 43018

\*автор-кореспондент, e-mail: [cdrr.mechanik@gmail.com](mailto:cdrr.mechanik@gmail.com)

# Ітераційна оптимізація складу бетону із заданою швидкістю тверднення за допомогою машинного навчання

Цитувати як:

Приходько, О.С., Приходько, В.О. (2025). Ітераційна оптимізація складу бетону із заданою швидкістю тверднення за допомогою машинного навчання. *Сучасні технології та методи розрахунків у будівництві*, 24, 331-339. [https://doi.org/10.36910/6775-2410-6208-2025-14\(24\)-27](https://doi.org/10.36910/6775-2410-6208-2025-14(24)-27)

© 2025, Приходько О.С., Приходько В.О.

У сучасній будівельній індустрії одним із ключових чинників підвищення економічної ефективності монолітного будівництва є швидкість обороту опалубки, яка визначається кінетикою набору міцності бетоном. Традиційні підходи до проектування бетонних сумішей орієнтовані переважно на забезпечення марочної міцності через 28 днів і часто не дозволяють оперативно визначити оптимальні компонентні складу для прискореного тверднення без проведення тривалих натурних випробувань. У цій роботі запропоновано та реалізовано підхід до розв'язання зворотної технологічної задачі – автоматизованого підбору складу бетонної суміші із заданою швидкістю тверднення. Методологічна основа дослідження поєднує предиктивне моделювання та стохастичну оптимізацію. Як аналітичний компонент використано ансамблеву регресійну модель Random Forest, навчену на відкритому наборі даних. Оптимізаційну задачу реалізовано через двоконтурний алгоритм: зовнішній цикл визначає часові інтервали досягнення проектної міцності, тоді як внутрішній цикл здійснює генерацію псевдовипадкових рецептур методом Монте-Карло (100 000 ітерацій) та їх подальше ранжування. У межах обчислювального експерименту для бетону класу С32/40 (40 МПа) встановлено технологічно можливу межу раннього досягнення міцності. Моделюванням ідентифіковано кластер із 236 сумішей, що забезпечують проектну міцність на третю добу тверднення. Аналіз компонентного складу отриманих рецептур показав їх узгодженість із відомими технологічними закономірностями для бетонів прискореного тверднення (High Early Strength Concrete). Зокрема, для досягнення цільових показників у надкороткий термін модель визначила як оптимальні параметри зниження водоцементного відношення до рівня 0,24–0,26 при вмісті цементу понад 450 кг/м<sup>3</sup>, що корелює із законом Абрамса та принципами отримання високофункціональних бетонів. Встановлено, що скорочення терміну тверднення до 3 днів збільшує собівартість суміші на близько 82% відносно 28-

добового циклу. Запропонований підхід може бути використаний як інструмент підтримки інженерно-технологічних рішень, оскільки забезпечує автоматизований пошук раціонального складу бетонної суміші з урахуванням обмежень за вартістю та необхідними темпами будівництва.

*Ключові слова:* раннє тверднення, технологія бетону, машинне навчання, Random Forest, оптимізація складу, метод Монте-Карло

## Вступ

### **Аналіз літературних джерел та постановка проблеми.**

Застосування методів машинного навчання (ML) у проектуванні бетонних сумішей дозволяє враховувати складні нелінійні взаємозв'язки між компонентами, умовами тверднення та властивостями матеріалу. Класичні підходи з використанням регресійних дерев, нейронних мереж та методів опорних векторів, як показано у роботі [1], демонструють ефективність для моделювання міцності бетону з урахуванням вторинних мінеральних добавок. Аналогічно, в [2] було запропоновано глибинну багатокритеріальну модель, яка дозволяє одночасно прогнозувати властивості та оптимізувати склад ультрависокоміцного бетону. В [3] порівняно CatBoost, k-NN та Support Vector Regression і виявлено перевагу градієнтних моделей у точності прогнозу. Вперше поєднання ML-моделювання з ймовірнісними методами було запропоновано в [4], що дало змогу оцінювати невизначеність прогнозованої міцності та підвищити надійність оптимізації складу. Окрім того, сучасні роботи демонструють зростаючу ефективність ансамблевих моделей та байєсівських підходів. Наприклад, в [5] було порівняно SVR, MLP, Gradient Boosting Regressor та XGBoost та показано, що ансамблеві алгоритми (GBR, XGBoost) забезпечують кращу точність прогнозу та стабільність моделей. Автори в [6] запропонували використання Gaussian Processes у поєднанні з багатокритеріальною оберненою оптимізацією для одночасного зменшення вартості та вуглецевого сліду бетонної суміші.

Додатково, автори в [7] показали перевагу гібридних моделей, що поєднують метаевристики та нейронні мережі. Аналогічно, в [8] застосували байєсівську оптимізацію для пошуку сталих бетонних сумішей із мінімальним глобальним вуглецевим слідом при збереженні міцності, демонструючи практичні переваги автоматизованого підбору складу. Останні дослідження також приділяють увагу багатокритеріальному прогнозуванню властивостей. В [9] було розроблено моделі, що одночасно прогнозують міцність на стиск, міцність на вигин та осадку суміші, підкреслюючи можливість використання ML для комплексного проектування бетонних сумішей.

Попри активне впровадження методів штучного інтелекту, більшість існуючих моделей вирішують переважно «пряму» задачу – прогнозування властивостей бетону за відомим складом. Натомість «зворотне»

проектування сумішей із заданою кінетикою набору міцності та оптимізацією економічних показників залишається недостатньо дослідженим. Відсутність формалізованих та автоматизованих методик для мінімізації часу тверднення та раціонального балансування вартості компонентів обґрунтовує актуальність і наукову новизну цього дослідження.

**Мета і завдання дослідження.** Метою роботи є розробка та верифікація методики автоматизованого проектування складу бетону, що забезпечує мінімізацію терміну досягнення проектної міцності, на основі поєднання предиктивного машинного моделювання та стохастичної оптимізації.

### **Матеріали та методи**

Дослідження базується на використанні відкритого набору даних (UCI Machine Learning Repository [10]), що містить 1030 експериментальних записів про вміст цементу, доменного шлаку, золи, води, суперпластифікатора, крупного та дрібного заповнювачів, а також вік зразка. Цільовою змінною є міцність на стиск в МПа.

Методика включає три етапи:

1. Навчання та валідація моделі. Використано алгоритм Random Forest Regressor (200 дерев рішень). Для оцінки адекватності моделі вибірку розділено на навчальну (80%) та тестову (20%). Оцінювались метрики MAE (середня абсолютна помилка) та  $R^2$  (коефіцієнт детермінації).

2. Двоконтурна симуляція. Розроблено алгоритм, що включає зовнішній цикл перебору часових інтервалів ( $t = \{3,7,14,28\}$  діб) та внутрішній цикл генерації псевдовипадкових сумішей методом Монте-Карло ( $N=100000$  ітерацій для кожного  $t$ ). Генерація здійснюється в межах діапазонів, визначених граничними значеннями навчальної вибірки, що забезпечує фізичну правдоподібність та технологічну реалістичність модельованих сумішей. Для кожної згенерованої рецептури навчена модель обчислює прогнозовану міцність та, в разі, коли вона більша за задану – додає її до вибірки прийнятих сумішей.

3. Економічна оцінка. Для відібраних сумішей, що задовольняють умову міцності, розраховується умовна собівартість, яка визначається як зважена сума добутоків вартості кожного компонента (у відносних одиницях) на його масову частку у складі. Такий підхід дозволяє використовувати умовну вартість як універсальний внутрішній критерій економічної доцільності без прив'язки до волатильних валютних показників чи регіональних цін.

### **Результати та обговорення**

Валідація прогновної моделі. Перед використанням моделі як інструменту генерації було проведено перевірку її точності на незалежних

тестових даних. На рисунку 1 наведено графік порівняння прогнозованих значень відносно реальних (а) та діаграма важливості ознак (б).

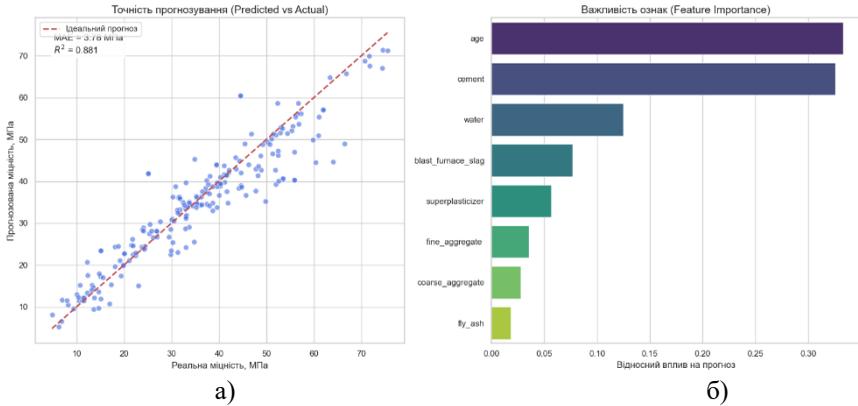


Рис. 1. Графік порівняння прогнозованих значень відносно реальних (а) та діаграма важливості ознак (б)

Як видно з рис. 1а, модель демонструє високу кореляцію між прогнозованими та реальними значеннями ( $R^2=0.881$ ,  $MAE=3.76$  МПа). Відсутність систематичного зміщення відносно діагоналі підтверджує здатність моделі коректно працювати у всьому діапазоні міцностей. Аналіз важливості ознак (рис. 1б) показує, що модель ідентифікувала вік (Age) та вміст цементу (Cement) як домінуючі фактори впливу, що фізично обґрунтовано.

Результати ітераційного пошуку. Задачею експерименту було знаходження складів для бетону класу С32/40 з мінімізацією часу тверднення. Симуляція показала, що досягнення цієї міцності технологічно можливе вже на 3-тю добу. Було ідентифіковано кластер із 236 сумішей, що задовольняють задані критерії. Статистичний аналіз отриманих рішень демонструє чітку тенденцію: переважна більшість змодельованих сумішей для цього терміну характеризується водоцементним відношенням у діапазоні 0,24–0,26 та вмістом цементу понад 450 кг/м<sup>3</sup>. Ці значення є результатом екстраполяції моделлю залежностей, наявних у навчальній вибірці, на область високих ранніх міцностей.

На рис. 2 представлено графіки візуалізації отриманих даних, що дозволяє виявити глибинні закономірності формування вартості бетонних сумішей залежно від вимог до кінетики набору міцності. Зокрема на рис. 2а представлена динаміка зміни мінімальної собівартості складів, що забезпечують 40 МПа, залежно від доступного часу тверднення. Встановлено, що забезпечення проектної міцності на 3-тю добу вимагає використання рецептури з умовною вартістю 7720 од., що на 82% дорожче

за базовий варіант для 28 діб (4246 од.). Найбільш різке зниження вартості спостерігається в інтервалі від 3 до 7 діб (падіння на 25%). Це свідчить про те, що екстремальне прискорення тверднення є найбільш ресурсоемним, тоді як помірне прискорення (до 7-14 діб) має більш полого криву здорожчання.

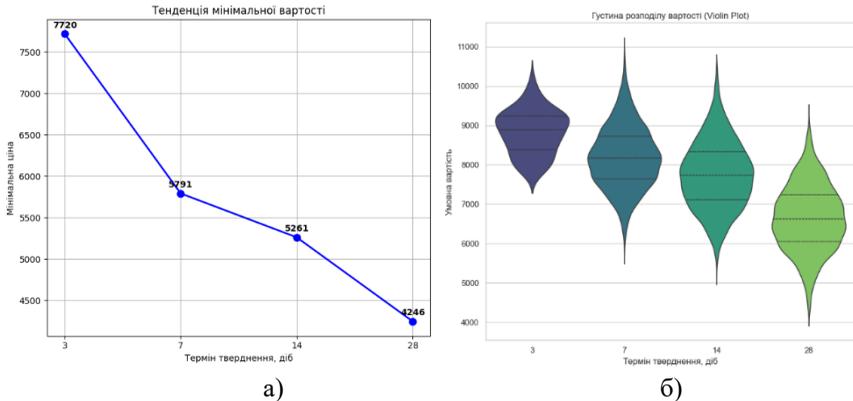


Рис. 2. Графіки візуалізації результатів підбору сумішей бетону

Аналіз густини розподілу вартості сумішей, представлений на рис. 2б у вигляді діаграми скрипкового типу, дозволяє оцінити зміну простору допустимих рішень залежно від часових обмежень. Як видно з діаграми, для терміну 3 доби (синій контур зліва) розподіл має форму «гриба» з концентрацією значень («центром мас») у верхній частині цінового діапазону ( $\approx 9000$  од.). Характерною особливістю є відсутність «хвоста» в нижній частині графіка. Це вказує на існування жорстких технологічних обмежень: доступний лише вузький коридор дорогих складів, здатних забезпечити проектну міцність у настільки ранній термін, що зумовлює низьку варіативність рішень.

Натомість для терміну 28 діб (салатовий контур справа) форма розподілу кардинально змінюється, набуваючи вигляду витягнутої «краплі». Спостерігається значне розширення діапазону в бік нижчих цін (формується довгий нижній «хвіст» аж до 4000 од.). Така структура даних свідчить про високу варіативність: модель знайшла множину альтернативних шляхів досягнення міцності (зокрема через використання дешевших заміників цементу), які стають доступними лише за умови достатнього часу для гідратації.

Отримані результати підтверджують гіпотезу про те, що моделі машинного навчання на базі дерев рішень здатні не лише інтерполювати відомі дані, а й знаходити гранично можливі з точки зору технології складу сумішей. Модель самостійно відтворила принцип "Water-Cement Ratio Law"

(емпіричний закон Абрамса), компенсуючи брак часу на набір міцності зниженням кількості води та збільшенням дози суперпластифікатора у "швидких" сумішах.

Економічний аналіз показує, що вимога ранньої розпалубки (на 3-тю добу) призводить до подорожчання матеріальної складової бетону майже вдвічі. Це дає інструмент для прийняття управлінських рішень: керівник проекту може порівняти додаткові витрати на бетон з економією від прискорення будівництва і обрати оптимальну стратегію.

Обмеженням дослідження є залежність від якості навчальної вибірки: модель не може запропонувати використання компонентів (наприклад, новітніх нано-добавок), які були відсутні в історичних даних.

### **Висновки**

Була розроблена методика ітераційного моделювання, яка дозволяє ефективно вирішувати зворотну технологічну задачу – проектування складу бетону із заданою кінетикою тверднення. Встановлено, що досягнення міцності, яка відповідає класу С32/40 (40 МПа), на 3-тю добу є технологічно можливим. Моделювання показало, що для забезпечення такої кінетики набору міцності раціональним є використання складів із підвищеним вмістом цементу (450–530 кг/м<sup>3</sup>) та низьким водоцементним відношенням, що узгоджується з практикою виготовлення швидкотверднучих бетонів [11]. Економічний аналіз виявив, що таке технологічне прискорення призводить до збільшення умовної вартості матеріалів на 82% порівняно з рецептурами для стандартного 28-добового циклу, що кількісно підтверджує залежність «швидкість–вартість». Візуалізація простору рішень показала, що зі збільшенням терміну тверднення експоненційно зростає варіативність допустимих сумішей, що відкриває можливості для економії ресурсів та використання вторинної сировини (золи, шлаків).

### **Конфлікти інтересів**

Автори заявляють, що у них немає конфлікту інтересів щодо поточного дослідження, включаючи фінансовий, особистий, авторський чи будь-який інший, який міг би вплинути на дослідження, а також на результати, наведені в цьому документі.

### **Фінансування**

Дослідження проводилося без фінансової підтримки.

### **Доступність даних**

Усі дані доступні в цифровій або графічній формі в основному тексті статті.

### **Використання штучного інтелекту**

Автори підтверджують, що при створенні поточної роботи вони не використовували технології штучного інтелекту.

### References

1. Qi, C., Huang, B., Wu, M., Wang, K., Yang, S., & Li, G. (2022). Concrete Strength Prediction Using Different Machine Learning Processes: The Effect of Slag, Fly Ash, and Superplasticizer. *Materials*, 15(15), 5369. <https://doi.org/10.3390/ma15155369>
2. Sun, C., Wang, K., Liu, Q., Wang, P., & Pan, F. (2023). Machine-learning-based comprehensive properties prediction and mixture design optimization of ultra-high-performance concrete. *Sustainability*, 15(21), 15338. <https://doi.org/10.3390/su152115338>
3. Beskopylny, A. N., Stel'makh, S. A., Shcherban', E. M., Mailyan, L. R., Meskhi, B., Razveeva, I., Chernil'nik, A., & Beskopylny, N. (2022). Concrete strength prediction using machine learning methods: CatBoost, k-nearest neighbors, support vector regression. *Applied Sciences*, 12(21), 10864. <https://doi.org/10.3390/app122110864>
4. Forsdyke, J. C., Zviashynski, B., Lees, J. M., & Conduit, G. J. (2023). Probabilistic selection and design of concrete using machine learning. *Data-Centric Engineering*, 4, e9. <https://doi.org/10.1017/dce.2023.5>
5. Nguyen, H., Vu, T., Vo, T. P., & Thai, H. T. (2021). Efficient machine learning models for prediction of concrete strengths. *Construction and Building Materials*, 266(Part B), 120950. <https://doi.org/10.1016/j.conbuildmat.2020.120950>
6. Pfeiffer, O. P., Gong, K., Severson, K. A., Chen, J., Gregory, J. R., Ghosh, S., Goodwin, R. T., & Olivetti, E. A. (2024). Bayesian design of concrete with amortized Gaussian processes and multi-objective optimization. *Cement and Concrete Research*, 177, 107406. <https://doi.org/10.1016/j.cemconres.2023.107406>
7. Li, P., Zhang, Y., Gu, J., et al. (2024). Prediction of compressive strength of concrete based on improved artificial bee colony-multilayer perceptron algorithm. *Scientific Reports*, 14, 6414. <https://doi.org/10.1038/s41598-024-57131-w>
8. Ament, S., Witte, A., Garg, N., & Kusuma, J. (2023). Sustainable concrete via Bayesian optimization. *arXiv*. <https://arxiv.org/abs/2310.18288>
9. Vargas, J. F., Oviedo, A. I., Ortega, N. A., Orozco, E., Gómez, A., & Londoño, J. M. (2024). Machine-learning-based predictive models for compressive strength, flexural strength, and slump of concrete. *Applied Sciences*, 14(11), 4426. <https://doi.org/10.3390/app14114426>
10. Yeh, I.-C. (1998). Concrete compressive strength [Dataset]. UCI Machine Learning Repository. <https://doi.org/10.24432/C5PK67>
11. Ananyachandran, Polipati & Vasugi, V.. (2017). Review of high early strength concrete. *International Journal of Civil Engineering and Technology*. 8. 697-705.

### Література

1. Qi C., Huang B., Wu M., Wang K., Yang S., Li G. Concrete Strength Prediction Using Different Machine Learning Processes: Effect of Slag, Fly Ash and Superplasticizer // *Materials*. – 2022. – Vol. 15, № 15. – P. 5369. – DOI: 10.3390/ma15155369.
2. Sun C., Wang K., Liu Q., Wang P., Pan F. Machine-Learning-Based Comprehensive Properties Prediction and Mixture Design Optimization of Ultra-High-

Performance Concrete // Sustainability. – 2023. – Vol. 15, № 21. – P. 15338. – DOI: 10.3390/su152115338.

3. Beskopylny A.N., Stel'makh S.A., Shcherban' E.M., Mailyan L.R., Meskhi B., Razveeva I., Chernil'nik A., Beskopylny N. Concrete Strength Prediction Using Machine Learning Methods: CatBoost, k-Nearest Neighbors, Support Vector Regression // Applied Sciences. – 2022. – Vol. 12, № 21. – P. 10864. – DOI: 10.3390/app122110864.

4. Forsdyke J.C., Zviashynski B., Lees J.M., Conduit G.J. Probabilistic Selection and Design of Concrete Using Machine Learning // Data-Centric Engineering. – 2023. – Vol. 4. – e9. – DOI: 10.1017/dce.2023.5

5. Nguyen H., Vu T., Vo T.P., Thai H.T. Efficient machine learning models for prediction of concrete strengths // Construction and Building Materials. – 2021. – Vol. 266, Part B. – Article 120950. – DOI: 10.1016/j.conbuildmat.2020.120950

6. Pfeiffer O.P., Gong K., Severson K.A., Chen J., Gregory J.R., Ghosh S., Goodwin R.T., Olivetti E.A. Bayesian design of concrete with amortized Gaussian processes and multi-objective optimization // Cement and Concrete Research. – 2024. – Vol. 177. – 107406. – DOI: 10.1016/j.cemconres.2023.107406

7. Li P., Zhang Y., Gu J., et al. Prediction of compressive strength of concrete based on improved artificial bee colony-multilayer perceptron algorithm // Sci Rep. – 2024. – Vol. 14. – 6414. – DOI: 10.1038/s41598-024-57131-w

8. Ament S., Witte A., Garg N., Kusuma J. Sustainable concrete via Bayesian optimization // arXiv. – 2023. – URL: <https://arxiv.org/abs/2310.18288>

9. Vargas J.F., Oviedo A.I., Ortega N.A., Orozco E., Gómez A., Londoño J.M. Machine-Learning-Based Predictive Models for Compressive Strength, Flexural Strength, and Slump of Concrete // Applied Sciences. – 2024. – Vol. 14, № 11. – 4426. – DOI: 10.3390/app14114426

10. Yeh I.-C. Concrete Compressive Strength [Dataset] // UCI Machine Learning Repository. – 1998. – DOI: 10.24432/C5PK67

11. Ananyachandran, Polipati & Vasugi, V.. Review on high early strength concrete. International Journal of Civil Engineering and Technology. 8. 697-705c – 2017

Відомості про статтю:	Article information:
Отримано 12.11.2025	Received 12.11.2025
Отримано у доопрацьованому вигляді 13.11.2025	Received in revised form 13.11.2025
Прийнято 25.11.2025	Accepted 25.11.2025
Опубліковано 25.12.2025	Published 25.12.2025

## O. S. Prykhodko

Associate Professor, Ph.D. in Engineering, ORCID: <https://orcid.org/0000-0001-8496-1295>  
Department of Applied Mathematics and Mechanics  
Lutsk National Technical University, Lvivska St., 75, Lutsk, Ukraine, 43018

## V. O. Prykhodko

Student PRM-11  
Lutsk National Technical University, Lvivska St., 75, Lutsk, Ukraine, 43018

\*corresponding author, e-mail: [cdr.mechanik@gmail.com](mailto:cdr.mechanik@gmail.com)

## Iterative Optimization of Concrete Mix Composition with a Target Hardening Rate Using Machine Learning

How to Cite:

Prykhodko O. S., Prykhodko V. O. (2025). Iterative Optimization of Concrete Mix Composition with a Target Hardening Rate Using Machine Learning. *Modern technologies and methods of calculations in construction*, 24, 331-339. [https://doi.org/10.36910/6775-2410-6208-2025-14\(24\)-27](https://doi.org/10.36910/6775-2410-6208-2025-14(24)-27)

*Abstract. In the modern construction industry, one of the key factors enhancing the economic efficiency of monolithic construction is the formwork turnover rate, which is determined by the kinetics of concrete strength gain. Traditional approaches to concrete mix design primarily focus on ensuring design strength after 28 days and often fail to rapidly determine optimal recipes for accelerated hardening without lengthy physical experiments. This paper proposes and implements an approach to solving the inverse technological problem: the automated design of concrete mix composition with a specified hardening rate. The methodological basis of the study combines predictive modeling and stochastic optimization. A Random Forest ensemble regression model, trained on an open dataset, was used as the analytical component. The optimization problem is implemented through a two-loop algorithm: the outer loop determines the time intervals for achieving the design strength, while the inner loop performs Monte Carlo generation of pseudo-random mix designs (100,000 iterations) followed by their ranking. Within the computational experiment for concrete class C32/40 (40 MPa), a technologically feasible limit for early strength achievement was established. The modeling identified a cluster of 236 mix designs capable of ensuring the design strength on the third day of hardening. Analysis of the component composition of the obtained mix designs demonstrated consistency with established technological principles for High Early Strength Concrete. Specifically, to achieve target performance indicators within an ultra-short timeframe, the model identified a reduction of the water-cement ratio to 0.24–0.26 and a cement content exceeding 450 kg/m<sup>3</sup> as optimal parameters, which correlates with Abrams' law and the principles of High Performance Concrete production. It was established that reducing the curing time to 3 days increases the cost of the mix by approximately 82% relative to the standard 28-day cycle. The proposed approach can serve as a support tool for engineering and technological decisions, as it provides an automated search for a rational concrete mix composition considering cost constraints and required construction schedules.*

*Keywords: early hardening, concrete technology, machine learning, Random Forest, mix optimization, Monte Carlo method*