

Свтушенко О. С., Заковоротний О. Ю.

АПРОКСИМАЦІЯ КРИТИЧНОЇ ШВИДКОСТІ ПОЇЗДА МЕТОДАМИ МАШИННОГО НАВЧАННЯ

Предметом дослідження є ефективність методів машинного навчання для апроксимації критичної швидкості в умовах нелінійних залежностей та обмеженого обсягу даних. **Мета статті** – порівняльне оцінювання трьох методів навчання з учителем щодо їх здатності апроксимувати критичну швидкість залізничного рухомого складу в умовах сильно нелінійних залежностей параметрів і обмеженого обсягу даних способом проведення низки експериментів і аналізу їх результатів. З огляду на окреслену мету необхідно виконати такі **завдання**: сформувати датасети малого й великого обсягу на основі математичної моделі криволінійного руху поїзда; реалізувати й навчити моделі багатопараметричного перцептрона, регресії на основі гауссівських процесів і регресії на опорних векторах у середовищі MATLAB; порівняти й оцінити точність апроксимації за метриками RMSE й R^2 на обох датасетах; визначити модель, що забезпечує найкращий компроміс між точністю та масштабованістю; обґрунтувати вибір оптимального методу для впровадження в системах підтримки прийняття рішень. **Методи**. Для генерації датасетів застосовано математичну модель криволінійного руху поїзда. Якість апроксимації оцінювалась за метриками RMSE й R^2 . Усі експерименти реалізовано в середовищі MATLAB. **Досягнуті результати**: моделі багатопараметричного перцептрона й регресії на основі гауссівських процесів продемонстрували високу точність прогнозування як на малому, так і на великому обсязі даних, до того ж перцептрон продемонстрував кращу масштабованість в умовах зростання обсягу навчальних даних, ніж регресія гауссівських процесів. **Висновки**. На основі порівняльного аналізу доцільно використовувати MLP як ключову модель для визначення критичної швидкості в систему підтримки прийняття рішень машиніста й діагностики залізничного транспорту. Упровадження запропонованого підходу дасть змогу підвищити безпеку руху поїздів в умовах реальної експлуатації, скоротити витрати на технічне обслуговування й забезпечити основу для розроблення адаптивних бортових систем контролю швидкості.

Ключові слова: критична швидкість; коливання рухомого складу; багатопараметричний перцептрон; регресії на основі гауссівських процесів; регресія на опорних векторах; апроксимація; машинне навчання; система підтримки прийняття рішень машиніста; криволінійний рух.

1. Вступ

Дослідження коливальних процесів і нестійкості руху залізничних транспортних засобів, обладнаних традиційними колісними парами з жорсткою посадкою, набуває дедалі більшої актуальності, що зумовлено необхідністю компенсувати погіршення технічного стану рухомого складу за допомогою комплексної оптимізації його руху.

Найменша швидкість, за якої виникають стійкі поперечні коливання системи "колісна пара – візок", називається критичною швидкістю. Визначення критичної швидкості є важливим завданням у розробленні та проектуванні залізничних транспортних засобів. Якщо транспортний засіб рухається зі швидкостями, що перевищують критичну, динамічні процеси, спричинені збуреннями, можуть не затухати, а навпаки, призводити до стійких коливань. Хоча такий рух може бути стійким у математичному сенсі, його прийнято називати нестійким рухом. Оскільки

інтенсивні коливання можуть спричинити значні бічні сили між колесом і рейкою та, як наслідок, підвищувати ризик зміщення колії або навіть сходу рухомого складу, такої поведінки необхідно уникати за нормальних умов експлуатації [1, 2]. Інакше кажучи, критична швидкість є верхньою межею допустимої швидкості руху залізничного транспортного засобу.

Традиційні аналітичні та чисельні методи визначення критичної швидкості потребують детальних математичних моделей рухомого складу з великою кількістю параметрів і є обчислювально витратними. Вони, як правило, не беруть до уваги ефекти деградації (зношування профілю коліс, гістерезис підвіски) і стохастичних збурень (стики рейок, нерівності колії), що призводить до надто оптимістичних оцінок запасу стійкості й робить їх непридатними для застосування в системах реального часу [3, 4]. У зв'язку з цим виникає потреба в розробленні альтернативних підходів, здатних забезпечити швидко й достатньо точно апроксимацію

критичної швидкості на основі обмеженого набору вимірюваних параметрів.

З огляду на постійне погіршення стану залізничної інфраструктури й рухомого складу, що призводить до динамічного зниження безпечної швидкості руху поїздів у режимі реального часу, здатність оперативно й надійно оцінювати критичну швидкість стала не тільки перевагою, а нагальною операційною необхідністю для запобігання нестійкості, спричиненій коливаннями, та зниження ризику сходу рухомого складу.

Практичне значення дослідження полягає у впровадженні отриманих результатів у бортові системи підтримки прийняття рішень машиніста, що сприятиме підвищенню безпеки залізничного руху, зниженню ризику сходу рухомого складу й оптимізації витрат на технічне обслуговування інфраструктури й рухомого складу в умовах реальної експлуатації.

2. Аналіз сучасних наукових публікацій. Визначення проблеми дослідження

Питанню критичної швидкості присвячено значну кількість досліджень. Перевищення критичної швидкості визначається як одна з потенційних причин сходу поїздів з колії [3]. Вивчено вплив колії та її основи на значення критичної швидкості [6–8], а також можливість установлення цього параметра за допомогою аналізу наслідків, які спричиняє рух на критичній швидкості для колії [7, 9]. Зазвичай розглядаються два обчислювальні підходи до оцінювання критичної швидкості: метод відстеження траєкторії, що забезпечує автоматизований розрахунок, і метод "грубого перебору". Проте через залежність від періодичності розв'язків метод відстеження траєкторії обмежений винятково суворо-періодичними режимами руху. Відповідно, метод "грубого перебору" є більш придатним для оцінювання критичної швидкості вздовж складних (неперіодичних) траєкторій [4].

Обчислення критичної швидкості є нетривіальним завданням. Це значення залежить від значної кількості змінних, постійних параметрів і характеристик руху поїзда, чимало з яких впливають на критичну швидкість вкрай нелінійно. З огляду на складність динаміки залізничних транспортних засобів безпосереднє обчислення критичної швидкості на основі наявної математичної моделі

динаміки криволінійного руху [10] є практично неможливим. Класичні методи оцінювання критичної швидкості ґрунтуються на лінеаризованому аналізі стійкості або часовому моделюванні з поступовим збільшенням швидкості. Однак окреслені підходи передбачають ідеалізовану геометрію колії, не беруть до уваги ефекти деградації (наприклад, зношування профілю коліс, гістерезису підвіски) й потребують високоточних моделей, що є обчислювально непридатними для реалізації в режимі реального часу. Крім того, вони часто не зважають на стохастичні збурення (наприклад, стики рейок, нерівності колії), що призводить до надто оптимістичних оцінок запасу стійкості.

Методи машинного навчання є перспективним інструментом для розв'язання подібних задач регресії в галузі залізничної динаміки, оскільки вони здатні виявляти складні нелінійні залежності безпосередньо з даних, не потребуючи явного задання фізичних рівнянь руху [11–13]. Зокрема нейронні мережі й методи на основі ядрових функцій уже застосовувалися для прогнозування динамічних навантажень у системі "колесо – рейка" [14, 15]. Проте порівняльний аналіз ефективності різних алгоритмів машинного навчання саме для задачі апроксимації критичної швидкості в умовах обмеженого обсягу даних залишається недостатньо дослідженим, що й зумовлює актуальність цієї роботи.

3. Мета й завдання дослідження

Метою статті є порівняльне оцінювання трьох методів навчання з учителем: багатопараметричного перцептрона, регресії на основі гауссівських процесів і регресії на опорних векторах – щодо їх здатності апроксимувати критичну швидкість залізничного рухомого складу в умовах сильно нелінійних залежностей параметрів і обмеженого обсягу даних способом проведення низки експериментів і аналізу їх результатів.

Для досягнення поставленої мети необхідно виконати низку завдань.

1. На основі наявної математичної моделі криволінійного руху поїзда сформувані два датасети – малого обсягу й великого обсягу, що відображають нелінійну залежність критичної швидкості від конусності колісної пари γ , номінального радіуса кочення r_0 та кутової жорсткості C .

2. Реалізувати й навчити три різні моделі машинного навчання в середовищі MATLAB і забезпечити відтворюваність експериментів.

3. Кількісно оцінити якість апроксимації кожної моделі за метриками середньоквадратичної похибки (RMSE) та коефіцієнта детермінації (R^2) окремо для малого й великого датасетів.

4. Дослідити масштабованість кожного методу способом порівняння точності на малому й великому датасетах.

5. На основі результатів порівняльного аналізу обґрунтувати вибір оптимального методу й визначити перспективи його впровадження як ключового модуля апроксимації критичної швидкості в системі підтримки прийняття рішень машиніста й у складі повної моделі криволінійного руху поїзда.

Найбільш ефективний метод надалі буде впроваджено для розроблення модуля оцінювання критичної швидкості в складі системи підтримки прийняття рішень машиніста і як компонента моделі криволінійного руху поїзда.

4. Матеріали й методи дослідження

Розглянемо поїзд, що рухається криволінійною ділянкою колії постійного радіуса кривизни $R = 500$. У межах наявної моделі криволінійного руху поїзда для критичної швидкості V_C застосовуються такі залежності: від конусності колісної пари γ , від номінального радіуса кочення r_0 , від кутової жорсткості зв'язків візка з кузовом C . Ці залежності є нелінійними й можуть бути умовно подані таким чином:

$$V_C \propto r_0 C / \sqrt{\gamma}.$$

З наведеного співвідношення випливає, що критична швидкість прямо пропорційна номінальному радіусу кочення r_0 і кутовій жорсткості C й обернено пропорційна кореню квадратному з конусності колісної пари γ . На основі цих залежностей апроксимація критичної швидкості є можливою.

Розглянемо інструменти, придатні для апроксимації критичної швидкості.

Багатошаровий перцептрон (Multilayer Perceptron – MLP) – клас нейронних мереж прямого поширення, що містять щонайменше три шари: вхідний, один або кілька прихованих шарів

і вихідний. За винятком вхідного шару, всі нейрони використовують нелінійну функцію активації.

Регресія на основі гауссівських процесів (Gaussian Process Regression – GPR) – потужний і гнучкий непараметричний метод регресії, що застосовується в машинному навчанні й статистиці. Він особливо корисний для задач з неперервними показниками, де зв'язок між вхідними змінними та вихідним значенням є невідомим або надзвичайно складним. GPR – це байєсівський підхід, який кількісно оцінює невизначеність у прогнозах, що робить його цінним для задач оптимізації та прогнозування часових рядів. Він ґрунтується на концепції гауссівського процесу – набору випадкових змінних, будь-яка скінченна підмножина яких має спільний гауссівський розподіл.

Регресія на опорних векторах (Support Vector Regression – SVR) – різновид методів опорних векторів (SVM), що використовується для задач регресії. Її мета полягає в знаходженні функції, яка найкраще прогнозує неперервне вихідне значення для заданого входу. SVR може застосовувати як лінійні, так і нелінійні ядра. Лінійне ядро обчислює простий скалярний добуток двох вхідних векторів, нелінійне ядро (наприклад, радіальна базисна функція – RBF) дає змогу виявляти більш складні закономірності в даних. Вибір ядра залежить від характеристик даних і складності задачі.

Для оцінювання продуктивності обраних методів у процесі прогнозування критичної швидкості використовувалися такі стандартні метрики:

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i^{pred} - y_i^{true})^2},$$

де y_i^{true} – справжнє (еталонне) значення критичної швидкості з датасету; y_i^{pred} – прогнозоване значення критичної швидкості; N – кількість зразків у тестовій вибірці.

Коефіцієнт детермінації (*Coefficient of Determination*) R^2 :

$$R^2 = 1 - \frac{\sum_{i=1}^N (y_i^{true} - y_i^{pred})^2}{\sum_{i=1}^N (y_i^{true} - \bar{y}^{true})^2},$$

де \bar{y}^{true} – це середнє значення істинних значень.

Для аналізу ефективності обраних моделей машинного навчання сформовано два датасети –

малого й великого обсягу, що містять варіації критичної швидкості, які відповідають різним комбінаціям параметрів (γ, r_0, C).

Для формування датасетів використовувалась попередньо побудована математична модель криволінійного руху поїзда. Набори даних були сформовані способом прямого перебору. Датасет малого обсягу подано 57 наборами значень параметрів γ, r_0, C як вхідні дані й відповідне їм значення V_c як вихідні дані. Датасет великого обсягу містить 212 наборів значень вхідних і вихідних даних. Фрагмент даних зі створених датасетів подано в табл. 1. Ці датасети застосовувалися для навчання моделей, реалізованих у MATLAB.

Таблиця 1. Фрагмент датасету

r_0	γ	C	V_c
0,1	0,05	1403	58
0,125	0,05	1403	63
...
0,8	0,05	1403	133,6

Графіки точності прогнозування, отримані під час експериментів, зображено на рис. 1–4. Істинні показники швидкості подано на графіках у вигляді пунктирної лінії, прогнози швидкості – у вигляді точок.

На рис. 1–2 продемонстровано точність прогнозування моделей, навчених на невеликому наборі даних. На малому наборі даних модель MLP прогнозує критичну швидкість із показником точності $R^2 = 0.9876$.

За таких саме умов за незначної кількості даних модель GPR здатна прогнозувати критичну швидкість із прийнятним показником точності $R^2 = 0.9987$. Видно, що в межах тестового набору даних прогнозовані значення критичної швидкості збігаються з реальними показниками (рис. 1).

Модель SVR за умови незначного обсягу даних може прогнозувати критичну швидкість з показником точності $R^2 = 0.9721$. Такий показник є недостатнім, що призводить до стабільних розбіжностей між прогнозами швидкості та реальними показниками (рис. 2).

Отже, за результатами експерименту можна помітити, що як MLP, так і GPR успішно виконують завдання прогнозування критичної швидкості, до того ж точність, якої досягає GPR, вища

за точність MLP. Натомість з усіх трьох моделей SVR демонструє найгірші результати у виконанні поставленого завдання в умовах незначного обсягу даних для навчання.

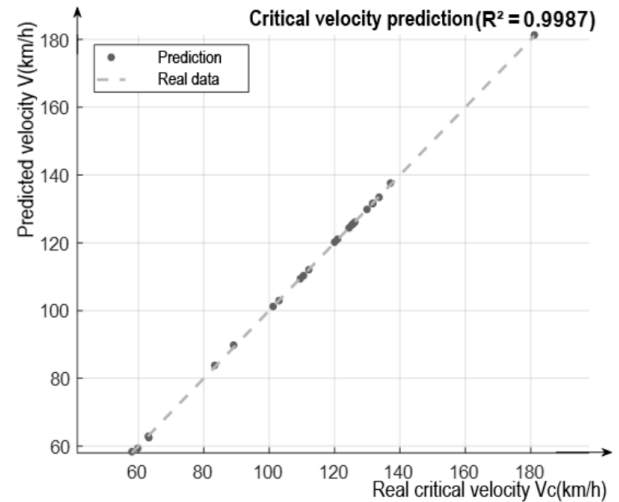


Рис. 1. Прогнозування критичної швидкості за допомогою моделі GPR, навченої на невеликому наборі даних

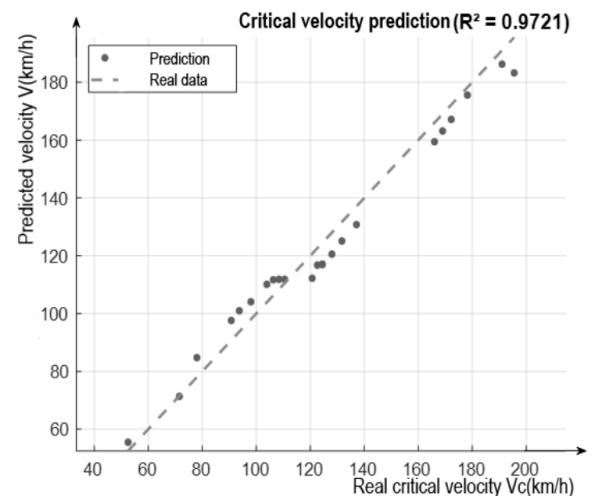


Рис. 2. Прогнозування критичної швидкості за допомогою моделі SVR, навченої на невеликому наборі даних

На рис. 3–4 подано результати для моделей, навчених на великому наборі даних. На цьому наборі даних модель MLP виконує прогнозування критичної швидкості з достатньо високим показником точності $R^2 = 0.9997$. Такий показник є майже ідеальним збігом прогнозів із реальними показниками, що можна побачити на графіку (рис. 3).

За саме таких умов модель GPR здатна прогнозувати критичну швидкість із показником точності $R^2 = 0.9989$.

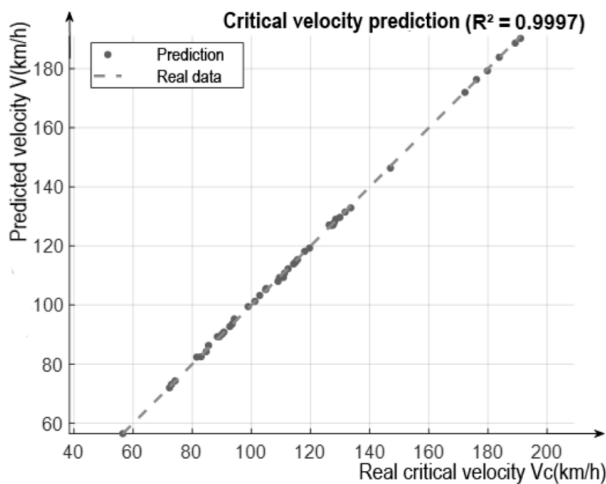


Рис. 3. Прогнозування критичної швидкості за допомогою моделі MLP, навченої на великому наборі даних

Модель SVR у разі значного обсягу даних може прогнозувати критичну швидкість з показником точності $R^2 = 0.9783$, що виражається у видимій різниці між прогнозованою та реальною критичними швидкостями (рис. 4).

На великому датасеті MLP і GPR залишаються ефективними, проте точність GPR знижується зі збільшенням обсягу даних, тоді як точність MLP зростає, що має кращу масштабованість. SVR продовжує демонструвати незадовільні результати як

на малому, так і на великому датасетах. Відповідно, з огляду на перспективи подальшого розширення даних і параметрів модель MLP є найбільш доцільним вибором для прогнозування критичної швидкості.




Рис. 4. Прогнозування критичної швидкості за допомогою моделі SVR, навченої на великому наборі даних

Для додаткового підтвердження ефективності MLP було порівняно залежності критичної швидкості від конусності колісної пари γ (за незмінних інших параметрів) (рис. 5).

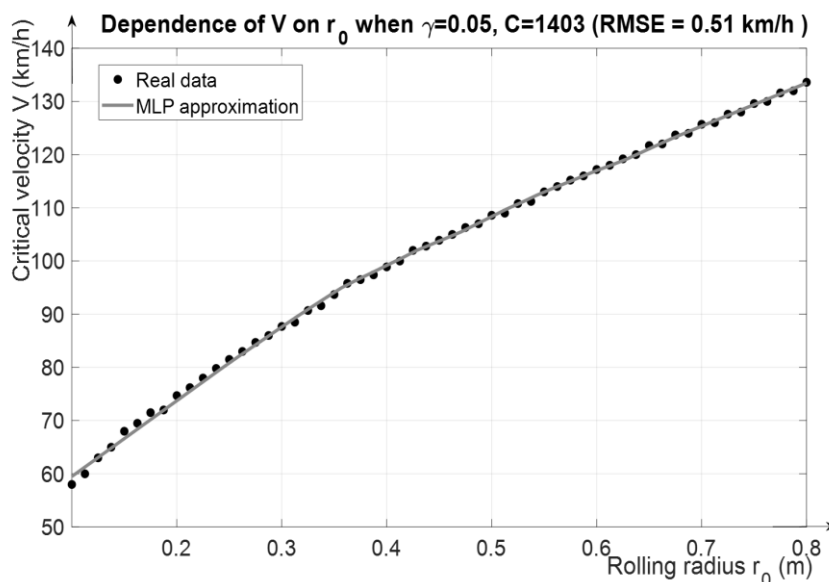


Рис. 5. Порівняння критичної швидкості та конусності колісної пари за незмінних інших параметрів

Як зображено на рис. 5, MLP апроксимує критичну швидкість із похибкою $RMSE = 0.51$ км/год. Така похибка є незначною з погляду задачі

прогнозування швидкості руху поїзда, що підтверджує дуже високий рівень точності прогнозів зазначеної моделі.

5. Результати дослідження

Порівняльний аналіз трьох моделей машинного навчання: багатошарового перцептрона, регресії гауссівських процесів і регресії опорних векторів – виявляє різні закономірності в роботі відповідно до розміру набору даних і залежностей базових параметрів (табл. 2).

Таблиця 2. Результати порівняльного аналізу

Модель	Малий набір даних	Великий набір даних
MLP	$R^2 = 0.9876$	$R^2 = 0.9997$
GPR	$R^2 = 0.9987$	$R^2 = 0.9989$
SVR	$R^2 = 0.9721$	$R^2 = 0.9783$

Усі моделі були навчені з використанням обмеженої кількості комбінацій параметрів руху поїзда. Як продемонстровано на рис. 1–3, на невеликому наборі даних як MLP, так і GPR успішно відобразили нелінійну залежність, що визначає критичну швидкість унаслідок досягнення високої точності щодо еталонних значень, отриманих з високоточної моделі криволінійного руху [8]. Зауважимо, що GPR продемонструвала дещо вищу точність, що можна пояснити її баєсівським характером і здатністю виводити плавні функціональні форми з розріджених даних. Натомість SVR (рис. 3) не змогла правильно апроксимувати критичну швидкість: її прогнози продемонстрували значне відхилення, особливо на крайніх значеннях діапазону конічності, що вказує на погану адаптивність до базової динаміки.

У процесі переходу до великих наборів даних поведінка моделей помітно змінилася (рис. 4–6). Ефективність MLP значно покращилася: значення R^2 зросло з 0.9876 до 0.9997, що підтверджує її високу здатність до навчання й масштабованість у разі збільшення обсягу даних. Це відповідає відомим перевагам глибоких мереж із прямим поширенням у процесі апроксимації високорозмірних нелінійних відображень за умови достатнього навчання. Водночас відповідно до показника R^2 точність GPR майже не змінилася. Це є свідченням недостатньої здатності до масштабування. Зі свого боку SVR залишився стабільно ненадійним для обох розмірів наборів даних: $R^2 = 0.9721$ на малому датасеті та $R^2 = 0.9783$ на великому. Додатковий експеримент з порівнянням критичної швидкості та конусності

колісної пари за незмінних інших параметрів підтверджує високу точність і надійність апроксимації швидкості за допомогою MLP та його перспективність для подальшого використання.

Результати демонструють, що MLP пропонує найкращий компроміс між точністю, надійністю та масштабованістю; GPR підходить для прототипування на невеликих наборах даних, але стає неефективним і менш точним із зростанням обсягу даних; SVR не підходить для цього конкретного завдання регресії в тестованих конфігураціях.

6. Висновки

Отже, у межах дослідження проведено порівняльний аналіз трьох методів навчання з учителем – багатошаровий перцептрон (MLP), гауссівська регресія процесів (GPR) і регресія на опорних векторах (SVR) – щодо здатності апроксимувати критичну швидкість залізничного рухомого складу в умовах сильно нелінійних залежностей параметрів і обмеженого обсягу даних. Для визначення продуктивності моделей обрано відповідні метрики, виконано порівняльну оцінку їх ефективності й точності. Порівняльний аналіз трьох моделей машинного навчання: багатошарового перцептрона (MLP), гауссівської регресії процесів (GPR) і регресії на опорних векторах (SVR) – виявив різні властивості продуктивності залежно від розміру датасету й характеру залежностей параметрів.

Результати показують, що і MLP, і GPR досягають високої точності прогнозування як на малих, так і на великих датасетах. У цьому разі MLP демонструє кращу масштабованість і покращення точності зі збільшенням обсягу датасету, тоді як ефективність GPR за тих самих умов знижується. Натомість для SVR властива недостатня точність прогнозування на всіх розмірах датасету.

Додатковий експеримент із виокремленням залежності критичної швидкості від конусності колісної пари γ за фіксованих r_0 та C підтверджує не лише загальну апроксимаційну здатність, але й збереження локальної чутливості – критичну вимогу для систем безпеки реального часу, наприклад системи підтримки прийняття рішень машиніста.

Відповідно, модель MLP обрано для подальшого впровадження як ключовий компонент модуля оцінювання критичної швидкості – складника

системи підтримки прийняття рішень машиніста й частини моделі криволінійного руху поїзда – і рекомендовано для виконання аналогічних задач в інших сферах діяльності.

Подальше дослідження обраної моделі буде присвячено модифікації її алгоритму й структури з огляду на фізичні параметри системи руху поїзда для підвищення якості досягнутих результатів.

Конфлікт інтересів

Автори декларують, що не мають конфлікту інтересів, зокрема фінансового, особистого, авторського чи будь-якого іншого характеру, який міг би вплинути на дослідження, а також на результати, опубліковані в цій статті.

References

- Alves Costa, P., Colaço, A., Calçada, R., Cardoso, A. (2014), "Critical velocity of railway tracks. Detailed and simplified approaches", *Transportation Geotechnics*, No. 2, pp. 30–32. DOI: <https://doi.org/10.1016/j.trgeo.2014.09.003>
- Iwnicki, S., Spiriyagin, M., Cole, C., McSweeney, T. (eds.) (2019), "Handbook of Railway Vehicle Dynamics", 2nd edn. Boca Raton: CRC Press. DOI: <https://doi.org/10.1201/9780429469398>
- Dusza, M. (2020), "Rail vehicle model motion analysis on curved track with vertical irregularity", *World Journal of Transport and Environment*, No. 130, pp. 75–84. DOI: <https://doi.org/10.5604/01.3001.0014.5456>
- Wu, Y., Fu, H., Bian, X. (2024), "Critical speed and dynamic response of high-velocity railway in ballastless track", *Journal of Physics: Conference Series*, No 2647. DOI: <https://doi.org/10.1088/1742-6596/2647/20/202001>
- Polach, O., Kaiser, I. (2012), "Comparison of methods analyzing bifurcation and hunting of complex rail vehicle models", *Journal of Computational and Nonlinear Dynamics*, No. 7(4), 041005. DOI: <https://doi.org/10.1115/1.4006825>
- Castanheira-Pinto, A., Fernández-Ruiz, J., Colaço, A., Alves Costa, P., Connolly, D.P. (2022), "A simplified approach for predicting the non-linear critical speed of railway tracks", *Transportation Geotechnics*, No. 37, 100869. DOI: <https://doi.org/10.1016/j.trgeo.2022.100869>
- Alves Costa, P., Soares, P., Colaço, A., Lopes, P., Connolly, D. (2020), "Railway critical velocity assessment: A simple experimental-analytical approach", *Soil Dynamics and Earthquake Engineering*, No. 134, 106156. DOI: <https://doi.org/10.1016/j.soildyn.2020.106156>
- Estaire, J., Crespo-Chacón, I. (2024), "On the use of dispersion curves to determine the critical velocity of railway tracks. Application to case studies", *Transportation Geotechnics*, No. 46, 101247. DOI: <https://doi.org/10.1016/j.trgeo.2024.101225>
- Mezher, S., Connolly, D., Woodward, P., Laghrouche, O., Pombo, J., Alves Costa, P. (2015), "Railway critical velocity - Analytical prediction and analysis", *Transportation Geotechnics*, No. 6, P. 84–96. DOI: <https://doi.org/10.1016/j.trgeo.2015.09.002>
- Yevtushenko, O. S., Zakovorotnyi, O. Yu. (2025), "Mathematical model of rolling stock vibrations on a curved track section for the on-board decision support system", *Systems of Control, Navigation and Communication*, No. 3, P. 33–36. DOI: <https://doi.org/10.26906/SUNZ.2025.3.033>
- Rasmussen, C. E., Williams, C. K. I. (2006), "Gaussian Processes for Machine Learning", Cambridge, MA: MIT Press.
- Goodfellow, I., Bengio, Y., Courville, A. (2016), "Deep Learning", Cambridge, MA: MIT Press.
- Smola, A. J., Schölkopf, B. (2004), "A tutorial on support vector regression", *Statistics and Computing*, No. 14(3), pp. 199–222
- Liu, H., Song, L., Xu, L., Yu, Z. (2025), "Identification of wheel-rail forces on high-speed railways based on physical model and hybrid recursive neural networks", *Engineering Structures*, No. 338, pp. 120547. DOI: <https://doi.org/10.1016/j.engstruct.2025.120547>
- Ye, Y., Shi, D., Krause, P., Hecht, M. (2019), "A data-driven method for estimating wheel flat length", *Vehicle System Dynamics*, No. 58, pp. 1329–1347. DOI: <https://doi.org/10.1080/00423114.2019.1620956>

Фінансування

Дослідження проводилося без фінансової підтримки.

Доступність даних

Дані будуть надані за обґрунтованим запитом.

Використання засобів штучного інтелекту

Автори застосовували технології ШІ (*Qwen-3.5*, *DeepL*) для перевірки граматики й орфографії. Після використання цих інструментів автори перевірили й відредагували контент і несуть повну відповідальність за зміст публікації. Автори підтверджують, що не застосовували технології штучного інтелекту для досягнення результатів, поданих у роботі.

Received (Надійшла) 01.04.2026

Accepted for publication (Прийнята до друку) 14.04.2026

Publication date (Дата публікації) 29.05.2026

Відомості про авторів / About the Authors

Євтушенко Олександр Сергійович – Національний технічний університет "Харківський політехнічний інститут", аспірант кафедри "Комп'ютерна інженерія та програмування", Харків, Україна;

Oleksandr Yevtushenko – National Technical University "Kharkiv Polytechnic Institute", Postgraduate Student, Department of Computer Engineering and Programming, Kharkiv, Ukraine;
 e-mail: Oleksandr.Yevtushenko@cs.khpi.edu.ua
 ORCID ID: <https://orcid.org/0009-0000-7798-8545>

Заковоротний Олександр Юрійович – доктор технічних наук, професор, Національний технічний університет "Харківський політехнічний інститут", завідувач кафедри "Комп'ютерна інженерія та програмування", Харків, Україна;

Oleksandr Zakovorotnyi – Doctor of Technical Sciences, Professor, National Technical University "Kharkiv Polytechnic Institute", Head of the Department of Computer Engineering and Programming, Kharkiv, Ukraine;
 e-mail: Oleksandr.Zakovorotnyi@khpi.edu.ua
 ORCID ID: <https://orcid.org/0000-0003-4415-838X>

ESTIMATION OF A TRAIN'S CRITICAL SPEED USING MACHINE LEARNING METHODS

The subject of this study is the effectiveness of machine learning methods for approximating critical speed under conditions of nonlinear dependencies and limited data volume. **The goal** of this article is to conduct a comparative evaluation of three teacher-guided learning methods in terms of their ability to estimate the critical speed of railway rolling stock under conditions of highly nonlinear parameter dependencies and limited data, through a series of experiments and an analysis of their results. **Given the stated objective, the following tasks must be performed:** create small- and large-scale datasets based on a mathematical model of a train's curvilinear motion; implement and train models of a multilayer perceptron, Gaussian process regression, and support vector machine regression in the MATLAB environment; conduct a comparative assessment of approximation accuracy using the RMSE and R^2 metrics on both datasets; identify the model that provides the best trade-off between accuracy and scalability; justify the selection of the optimal method for implementation in the DSS. **Methods.** A mathematical model of a train's curvilinear motion was used to generate the datasets. The quality of the approximation was evaluated using the RMSE and R^2 metrics. All experiments were implemented in MATLAB. **The following results were obtained:** the multilayer perceptron and Gaussian process regression models demonstrated high prediction accuracy for both small and large datasets, with the perceptron showing better scalability as the training dataset size increased than Gaussian process regression. **Conclusions.** Based on the comparative analysis, it is advisable to use the MLP as the primary model for determining the critical speed in the train driver's decision support system and railway transport diagnostics. Implementing the proposed approach will improve train safety under actual operating conditions, reduce maintenance costs, and provide a foundation for the development of adaptive on-board speed control systems

Keywords: critical speed; rolling stock vibrations; multilayer perceptron; Gaussian process-based regression; support vector regression; approximation; machine learning; train driver decision support system; curved-track movement.

Бібліографічні описи / Bibliographic descriptions

Євтушенко О. С., Заковоротний О. Ю. Апроксимація критичної швидкості поїзда методами машинного навчання. *Автоматизовані системи управління та прилади автоматики*. 2026. № 2 (189). С. 276–283. DOI: <https://doi.org/10.30837/0135-1710.2026.189.276>

Yevtushenko, O., Zakovorotnyi, O. (2026), "Estimation of a train's critical speed using machine learning methods", *Management Information System and Devices*, No. 2 (189), P. 276–283. DOI: <https://doi.org/10.30837/0135-1710.2026.189.276>