

УДК 004.8:630*432.31

МЕТОДЫ МАШИННОГО ОБУЧЕНИЯ ДЛЯ ОЦЕНКИ ПАРАМЕТРОВ МОДЕЛЕЙ РАСПРОСТРАНЕНИЯ ПОЖАРОВ ПРИБРЕЖНО-ВОДНОЙ РАСТИТЕЛЬНОСТИ

Старосика Даниил Олегович,

аспирант кафедры Математика и информатика

Донской Государственный Технический Университет, г. Ростов-на-Дону, Россия

E-mail: s.daniil4809@yandex.ru

Аннотация

В статье представлен сравнительный анализ методов машинного обучения для решения обратных задач оценки параметров моделей распространения пожаров прибрежно-водной растительности. Рассмотрены особенности моделирования пожаров тростниковых экосистем, связанные с высокой влажностью топлива и ограниченностью наблюдательных данных. Выполнен обзор подходов, основанных на суррогатном моделировании, ассимиляции данных и физически-информированных нейронных сетях (PINN). Показано, что гибридные методы, объединяющие физические модели и алгоритмы глубокого обучения, обладают наибольшим потенциалом для оценки параметров в условиях неопределённости. Полученные результаты могут быть использованы при разработке систем мониторинга и прогнозирования природных пожаров.

Ключевые слова: машинное обучение, обратные задачи, моделирование пожаров, прибрежно-водная растительность, тростник, физически-информированные нейронные сети, PINN, калибровка моделей.

MACHINE LEARNING METHODS FOR ESTIMATING PARAMETERS OF COASTAL VEGETATION FIRE SPREAD MODELS (CASE STUDY: AZOV COAST AND DON RIVER LOWER REACHES)

Starosika Daniel Olegovich,

Don State Technical University, Rostov-on-Don, Russia

E-mail: s.daniil4809@yandex.ru

ABSTRACT

This paper presents a comparative analysis of machine learning methods for solving inverse problems of parameter estimation in coastal vegetation fire spread models. The study discusses key challenges of reed fire modeling, including high fuel moisture and limited observational data. Approaches based on surrogate modeling, data assimilation, and Physics-Informed Neural Networks (PINNs) are reviewed. The results show that hybrid methods combining physical models with deep learning techniques offer the greatest potential for parameter estimation under

uncertainty. The findings may support the development of wildfire monitoring and forecasting systems.

Keywords: machine learning, inverse problems, fire modeling, coastal vegetation, reed, physics-informed neural networks, PINN, model calibration.

1. Введение

Проблема природных пожаров остается одной из наиболее актуальных экологических и социально-экономических задач современности. В условиях изменения климата во многих регионах мира наблюдается увеличение продолжительности пожароопасных периодов и рост частоты экстремальных пожаров [1]. Особую категорию риска представляют пожары прибрежно-водной растительности, характерные для водно-болотных экосистем юга России, включая дельту реки Дон и побережье Азовского моря [2].

Пожары в зарослях тростника (*Phragmites australis*) отличаются высокой скоростью распространения и существенной зависимостью от гидрометеорологических условий [3]. Вместе с тем существующие модели распространения пожаров преимущественно разрабатывались для лесных экосистем и не всегда обеспечивают требуемую точность при моделировании горения прибрежно-водной растительности. Одной из ключевых проблем является неопределенность параметров моделей. Для корректного прогнозирования необходимы данные о влажности топлива, характеристиках растительного слоя и параметрах тепло- и массопереноса, получение которых в условиях чрезвычайных ситуаций затруднено. В связи с этим особую актуальность приобретает решение обратных задач, направленных на восстановление параметров модели по данным наблюдений, включая спутниковые снимки, результаты дистанционного зондирования и сведения о положении фронта пожара.

Традиционные методы решения обратных задач требуют многократного запуска вычислительно сложных моделей и зачастую оказываются недостаточно эффективными для оперативного прогнозирования [4]. Современные методы машинного обучения и искусственного интеллекта позволяют существенно ускорить процесс оценки параметров и повысить устойчивость решений в условиях неполных и зашумленных данных. Однако большинство существующих исследований ориентировано на лесные пожары или урбанизированные территории, тогда как задачи моделирования пожаров прибрежно-водной растительности остаются изученными недостаточно [5].

Целью настоящей работы является сравнительный анализ методов машинного обучения для определения параметров моделей распространения пожаров прибрежно-водной растительности в условиях неопределенности, характерной для региона Азовского побережья и низовьев Дона.

Для достижения поставленной цели решаются следующие задачи:

Выявление физико-математических особенностей моделирования пожаров прибрежно-водной растительности.

Анализ современных методов искусственного интеллекта и машинного обучения для решения обратных задач калибровки.

Сравнение рассматриваемых подходов с учетом специфики региональных условий мониторинга.

Обоснование перспективного направления дальнейших исследований.

2. Физико-математические особенности моделирования пожаров тростника

Для выбора методов оценки параметров необходимо учитывать особенности распространения пожаров в зарослях тростника и другой прибрежно-водной

растительности. По сравнению с лесными пожарами данные процессы характеризуются повышенной неопределенностью параметров и более сложным взаимодействием с окружающей средой.

Одним из ключевых факторов является высокая влажность топлива. Влажность живого тростника может достигать 80–90 %, что приводит к дополнительным затратам энергии на испарение влаги и существенно влияет на скорость распространения огня. Кроме того, данный параметр значительно изменяется в зависимости от сезона и гидрологического режима территории, являясь одним из основных источников неопределенности модели. Важную роль играют аэродинамические процессы в прибрежной зоне. На границе водной и сухопутной поверхности формируются специфические ветровые режимы и структуры турбулентности, которые могут существенно отличаться от условий, предполагаемых в традиционных лесопожарных моделях. Дополнительную сложность создает структура растительного слоя. Заросли тростника представляют собой пористую среду с преимущественно вертикальной ориентацией стеблей, что допускает различные механизмы распространения горения и требует учета пространственной неоднородности тепло- и массопереноса.

Существенным ограничением остается недостаток данных наблюдений. Информация о развитии пожара часто поступает из спутниковых систем дистанционного мониторинга с ограниченным пространственно-временным разрешением и может содержать значительный уровень шума. Для региона низовьев Дона ситуация дополнительно осложняется выраженной сезонной изменчивостью состояния растительности и метеорологических условий [6].

Перечисленные особенности обуславливают необходимость применения методов оценки параметров, способных эффективно работать в условиях неполных данных, высокой неопределенности и нелинейного характера процессов распространения пожара.

3. Постановка обратной задачи оценки параметров

Распространение пожара в растительном покрове может быть описано системой уравнений тепло- и массопереноса, учитывающих процессы теплопроводности, конвективного переноса, горения топлива и теплообмена с окружающей средой. Параметры таких моделей определяются свойствами растительности и условиями окружающей среды, однако их значения часто известны лишь приближенно.

В рамках настоящей работы рассматривается задача оценки параметров модели по данным наблюдений. Вектор неизвестных параметров может включать эффективную теплопроводность растительного слоя, критическую влажность воспламенения, коэффициенты аэродинамического сопротивления и кинетические характеристики процесса выгорания топлива.

Пусть имеются наблюдения состояния пожара, полученные по данным дистанционного мониторинга или наземных измерений. Тогда обратная задача заключается в определении такого набора параметров модели, который обеспечивает наилучшее согласование результатов моделирования с наблюдаемыми данными. Математически задача формулируется как задача минимизации функционала невязки между расчетными и наблюдаемыми характеристиками пожара с учетом регуляризации, обеспечивающей устойчивость решения и физическую корректность оцениваемых параметров. Основными трудностями решения являются высокая вычислительная стоимость прямого моделирования, наличие множества локальных минимумов целевой функции и ограниченный объем доступных наблюдений. Эти особенности делают актуальным применение методов машинного обучения, способных эффективно работать в условиях неопределенности и неполноты данных.

4. Обзор методов машинного обучения для решения задачи

В последние годы для решения обратных задач калибровки моделей природных процессов активно применяются методы искусственного интеллекта и машинного обучения. В зависимости от способа использования физических знаний и наблюдательных данных данные подходы можно разделить на несколько основных групп.

4.1. Суррогатное моделирование

Суррогатные модели предназначены для замены вычислительно сложных физических моделей их приближенными аналогами, построенными с использованием методов машинного обучения. В качестве аппроксиматоров могут использоваться нейронные сети, гауссовские процессы и другие регрессионные модели.

Основным преимуществом данного подхода является высокая скорость вычислений после завершения этапа обучения. Вместе с тем качество получаемых оценок существенно зависит от полноты обучающей выборки, а точность может снижаться при возникновении условий, отсутствовавших в обучающих данных.

4.2. Методы ассимиляции данных

Методы ассимиляции данных обеспечивают совместное использование результатов моделирования и поступающих наблюдений для последовательного уточнения состояния системы и её параметров. Наиболее распространённым подходом является ансамблевый фильтр Калмана (EnKF), позволяющий учитывать неопределённость как модели, так и измерений [7].

Данные методы хорошо адаптируются к изменяющимся условиям и обеспечивают обновление параметров в режиме реального времени. Однако их применение осложняется высокой нелинейностью процессов горения и ограниченной доступностью наблюдений, что может приводить к снижению устойчивости оценок.

4.3. Физически-информированные нейронные сети

Физически-информированные нейронные сети (Physics-Informed Neural Networks, PINN) представляют собой одно из наиболее активно развивающихся направлений в области научного машинного обучения. В отличие от традиционных нейронных сетей, при обучении PINN учитывается не только ошибка относительно наблюдений, но и выполнение соответствующих физических уравнений [8].

Интеграция физических ограничений позволяет эффективно использовать ограниченные объёмы данных и получать решения, согласованные с фундаментальными законами тепло- и массопереноса. Кроме того, параметры модели могут рассматриваться как обучаемые переменные, что делает PINN удобным инструментом для решения обратных задач [9].

Для задач моделирования пожаров прибрежно-водной растительности данный подход представляет особый интерес благодаря способности восстанавливать характеристики процесса даже при фрагментарных наблюдениях и наличии значительной неопределённости исходной информации [10].

5. Сравнительный анализ и региональные особенности

Сравнительный анализ рассмотренных подходов показывает, что их эффективность существенно зависит от объёма доступных данных и особенностей моделируемой среды. Для задач оценки параметров пожаров прибрежно-водной растительности особенно важны способность работать с ограниченным количеством наблюдений, учёт физических закономерностей процесса горения и возможность адаптации к изменяющимся условиям.

Результаты сравнительного анализа представлены в таблице 1.

Таблица 1. Сравнение методов оценки параметров для пожаров тростника

Метод	Точность при малых данных	Учет влажности топлива	Скорость работы (инференс)	Интерпретируемость	Применимость для Азовского региона
Градиентная оптимизация	Низкая	Средняя	Низкая	Высокая	Низкая (долго)
Суррогатные модели (ML)	Средняя	Высокая	Высокая	Низкая	Средняя (нужны данные)
Фильтр Калмана (EnKF)	Высокая	Высокая	Средняя	Средняя	Высокая
PINN	Высокая	Высокая	Высокая*	Средняя	Наиболее высокая

* после этапа обучения

Для региона Азовского побережья и низовьев Дона одной из основных проблем является недостаток верифицированных данных наблюдений. Большинство существующих моделей разрабатывалось на основе данных других природно-климатических условий, что ограничивает возможность их прямого применения. Одним из перспективных решений является использование методов трансферного обучения, позволяющих адаптировать предварительно обученные модели к региональным особенностям на основе ограниченного объёма локальных данных. Не менее важным требованием является интерпретируемость результатов моделирования. При практическом использовании в системах поддержки принятия решений необходимо понимать влияние отдельных факторов на прогнозируемое развитие пожара. В этом отношении физически-информированные нейронные сети обладают преимуществом перед полностью эмпирическими моделями, поскольку сохраняют связь между вычисляемыми параметрами и физическими характеристиками процесса [11].

С учётом рассмотренных критериев наиболее перспективным направлением представляются гибридные подходы, объединяющие физическое моделирование, методы машинного обучения и механизмы адаптации к региональным данным.

6. Заключение

В работе выполнен анализ методов машинного обучения, применяемых для решения обратных задач оценки параметров моделей распространения пожаров прибрежно-водной растительности. Рассмотрены подходы, основанные на суррогатном моделировании, ассимиляции данных и физически-информированных нейронных сетях.

Проведённое сравнение показало, что наиболее перспективными для решения задач калибровки в условиях неопределённости и ограниченности наблюдений являются гибридные подходы на основе PINN, обеспечивающие совместное использование физических закономерностей и данных наблюдений.

Дальнейшие исследования целесообразно направить на разработку специализированных PINN-архитектур для моделирования пожаров тростниковой растительности и их интеграцию в региональные системы мониторинга и прогнозирования природных пожаров.

Список литературы:

1. Chao Wu, Menghui Wang, Chenxi Lu, Sergey Venevsky, Vera Sorokina, Valerii Kulygin, Sergey Berdnikov. Climate-induced fire regimes in the Russian biodiversity hotspots. *Global Ecology and Conservation*. 2018; 16 :e00495. <https://doi.org/10.1016/j.gecco.2018.e00495>

2. Damasceno-Junior G.A., Pereira A.M.M., Saharjo B.H., et al. Flood-Fire Interplays in Wetlands: The Rising of an Actionable Field of Study. *Wetlands*. 2025; 45 (8) :122. <https://doi.org/10.1007/s13157-025-02005-8>
3. D. Morvan, S. Méradji, G. Accary. Physical modelling of fire spread in Grasslands. *Fire Safety Journal*. 2009; 44 (1) :50-61. <https://doi.org/10.1016/j.firesaf.2008.03.004>
4. Angelo Alessandri, Patrizia Bagnerini, Mauro Gaggero, Luca Mantelli. Parameter estimation of fire propagation models using level set methods. *Applied Mathematical Modelling*. 2021; 92 :731-747. <https://doi.org/10.1016/j.apm.2020.11.030>
5. Piyush Jain, Sean C.P. Coogan, Sriram Ganapathi Subramanian, Mark Crowley, Steve Taylor, Mike D. Flannigan. A review of machine learning applications in wildfire science and management. *Environmental Reviews*. 2020; 28 (4) :478-505. <https://doi.org/10.1139/er-2020-0019>
6. Meriame Mohajane, Romulus Costache, Firoozeh Karimi, Quoc Bao Pham, Ali Essahlaoui, Hoang Nguyen, Giovanni Laneve, Fatiha Oudija. Application of remote sensing and machine learning algorithms for forest fire mapping in a Mediterranean area. *Ecological Indicators*. 2021; 129 :107869. <https://doi.org/10.1016/j.ecolind.2021.107869>
7. Tengjiao Zhou, Long Ding, Jie Ji, Lin Li, Weiwei Huang. Ensemble transform Kalman filter (ETKF) for large-scale wildland fire spread simulation using FARSITE tool and state estimation method. *Fire Safety Journal*. 2019; 105 :95-106. <https://doi.org/10.1016/j.firesaf.2019.02.009>
8. M. Raissi, P. Perdikaris, G.E. Karniadakis. Physics-informed neural networks: A deep learning framework for solving forward and inverse problems involving nonlinear partial differential equations. *Journal of Computational Physics*. 2019; 378 :686-707. <https://doi.org/10.1016/j.jcp.2018.10.045>
9. Luning Sun, Han Gao, Shaowu Pan, Jian-Xun Wang. Surrogate modeling for fluid flows based on physics-constrained deep learning without simulation data. *Computer Methods in Applied Mechanics and Engineering*. 2020; 361 :112732. <https://doi.org/10.1016/j.cma.2019.112732>
10. Bin Xu, Yun Zou, Gaofeng Sha, Liang Yang, Guixi Cai, Yang Li. Sparse wavefield reconstruction based on Physics-Informed neural networks. *Ultrasonics*. 2025; 149 :107582. <https://doi.org/10.1016/j.ultras.2025.107582>
11. Alejandro Barredo Arrieta, Natalia Díaz-Rodríguez, Javier Del Ser, Adrien Bennetot, Siham Tabik, Alberto Barbado, Salvador Garcia, Sergio Gil-Lopez, Daniel Molina, Richard Benjamins, Raja Chatila, Francisco Herrera. Explainable Artificial Intelligence (XAI): Concepts, taxonomies, opportunities and challenges toward responsible AI. *Information Fusion*. 2020; 58 :82-115. <https://doi.org/10.1016/j.inffus.2019.12.012>

References:

1. Chao Wu, Menghui Wang, Chenxi Lu, Sergey Venevsky, Vera Sorokina, Valerii Kulygin, Sergey Berdnikov. Climate-induced fire regimes in the Russian biodiversity hotspots. *Global Ecology and Conservation*. 2018; 16 :e00495. <https://doi.org/10.1016/j.gecco.2018.e00495>

2. Damasceno-Junior G.A., Pereira A.M.M., Saharjo B.H., et al. Flood-Fire Interplays in Wetlands: The Rising of an Actionable Field of Study. *Wetlands*. 2025; 45 (8) :122. <https://doi.org/10.1007/s13157-025-02005-8>
3. D. Morvan, S. Méradji, G. Accary. Physical modelling of fire spread in Grasslands. *Fire Safety Journal*. 2009; 44 (1) :50-61. <https://doi.org/10.1016/j.firesaf.2008.03.004>
4. Angelo Alessandri, Patrizia Bagnerini, Mauro Gaggero, Luca Mantelli. Parameter estimation of fire propagation models using level set methods. *Applied Mathematical Modelling*. 2021; 92 :731-747. <https://doi.org/10.1016/j.apm.2020.11.030>
5. Piyush Jain, Sean C.P. Coogan, Sriram Ganapathi Subramanian, Mark Crowley, Steve Taylor, Mike D. Flannigan. A review of machine learning applications in wildfire science and management. *Environmental Reviews*. 2020; 28 (4) :478-505. <https://doi.org/10.1139/er-2020-0019>
6. Meriame Mohajane, Romulus Costache, Firoozeh Karimi, Quoc Bao Pham, Ali Essahlaoui, Hoang Nguyen, Giovanni Laneve, Fatiha Oudija. Application of remote sensing and machine learning algorithms for forest fire mapping in a Mediterranean area. *Ecological Indicators*. 2021; 129 :107869. <https://doi.org/10.1016/j.ecolind.2021.107869>
7. Tengjiao Zhou, Long Ding, Jie Ji, Lin Li, Weiwei Huang. Ensemble transform Kalman filter (ETKF) for large-scale wildland fire spread simulation using FARSITE tool and state estimation method. *Fire Safety Journal*. 2019; 105 :95-106. <https://doi.org/10.1016/j.firesaf.2019.02.009>
8. M. Raissi, P. Perdikaris, G.E. Karniadakis. Physics-informed neural networks: A deep learning framework for solving forward and inverse problems involving nonlinear partial differential equations. *Journal of Computational Physics*. 2019; 378 :686-707. <https://doi.org/10.1016/j.jcp.2018.10.045>
9. Luning Sun, Han Gao, Shaowu Pan, Jian-Xun Wang. Surrogate modeling for fluid flows based on physics-constrained deep learning without simulation data. *Computer Methods in Applied Mechanics and Engineering*. 2020; 361 :112732. <https://doi.org/10.1016/j.cma.2019.112732>
10. Bin Xu, Yun Zou, Gaofeng Sha, Liang Yang, Guixi Cai, Yang Li. Sparse wavefield reconstruction based on Physics-Informed neural networks. *Ultrasonics*. 2025; 149 :107582. <https://doi.org/10.1016/j.ultras.2025.107582>
11. Alejandro Barredo Arrieta, Natalia Díaz-Rodríguez, Javier Del Ser, Adrien Bennetot, Siham Tabik, Alberto Barbado, Salvador Garcia, Sergio Gil-Lopez, Daniel Molina, Richard Benjamins, Raja Chatila, Francisco Herrera. Explainable Artificial Intelligence (XAI): Concepts, taxonomies, opportunities and challenges toward responsible AI. *Information Fusion*. 2020; 58 :82-115. <https://doi.org/10.1016/j.inffus.2019.12.012>