arXiv:2601.01009v1 [cs.LG] 3 Jan 2026

基于独立机器学习算法的数据驱动评估：混凝土配合比组成对氯离子传输的影响

Mojtaba Aliasghar-Mamaghani[a,*], MohammadrezaKhalafi[b]

[a]博士后研究员，土木、建筑与环境工程系，德克萨斯大学奥斯汀分校，美国得克萨斯州奥斯汀[b]学生，土木工程系，沙里夫理工大学，伊朗德黑兰

文章信息

关键词：机器学习
氯离子侵入 混凝土
时间演变 腐蚀 适用性 人工智能

摘要

本文采用数据驱动方法，确定混凝土配合比组成对混凝土结构中氯离子随时间的演化的影响。这对于评估处于侵蚀性环境中的土木基础设施的使用寿命至关重要。所采用的方法依赖于若干简单和复杂的独立机器学习（ML）算法，主要目标是对底层隐含相关性的无偏预测建立信心。简单算法包括线性回归（LR）、k近邻（KNN）回归和核岭回归（KRR）。复杂算法包括支持向量回归（SVR）、高斯过程回归（GPR）以及两类人工神经网络，即前馈网络（多层感知机，MLP）和门控循环单元（GRU）。MLP架构无法显式处理序列数据，而GRU则解决了这一局限。本文采用了一个综合数据集，并对机器学习算法的性能进行了评估，其中KRR、GPR和MLP表现出较高的准确性。鉴于所采用的混凝土配合比具有多样性，GRU无法准确重现测试集中的响应。进一步分析阐明了配合组分对氯离子随时间演化的贡献。高斯过程回归模型所得结果通过清晰且可解释的趋势揭示了潜在相关性。MLP、SVR和KRR也对总体趋势给出了可接受的估计。大多数配合组分与氯离子含量呈反向关系，而少数组分表现出直接相关性。这些研究结果凸显了代理方法在描述氯离子侵入所涉及的物理过程及其相关性方面的潜力，最终旨在延长土木基础设施的使用寿命。

1. 引言

腐蚀是导致土木基础设施构件长期劣化的主要原因之一。混凝土桥梁是日常通勤网络中常见的建造体系。在混凝土凝结的早期阶段，由于混凝土介质具有较高的碱度，钢筋材料周围会形成一层保护膜。这层保护层的形成使钢筋材料处于钝化状态，从而有效降低腐蚀风险。电化学氧化还原反应决定了发生腐蚀的倾向。保护膜的破坏会显著加快腐蚀反应速率；此后，便会出现严重的适用性问题 [1–5]。

腐蚀会对混凝土结构造成多种有害影响。具体而言，腐蚀会损害钢筋材料的力学特性和变形能力，也会影响钢与混凝土之间的黏结性能 [6–12]。此外，腐蚀产物的形成——其体积通常是原始反应物的 2 至 6.4 倍 [13]——会在周围混凝土中产生显著的被动压力，导致拉应变，随后使受影响区域发生劣化或剥落 [14–16]。

混凝土结构的适用性会受到钢筋材料所在位置氯离子含量的显著影响。氯离子会破坏钢筋周围最初形成的保护层，从而使钢筋钝化膜破坏，并显著提高腐蚀速率 [1, 17–19, 5]。此前已有多项研究提出，以替代材料取代传统钢筋，以规避钢筋腐蚀带来的适用性问题 [20–23]。尽管为此付出了大量努力，钢筋混凝土结构和预应力混凝土结构仍在全球占据主导地位 [12, 24–26]。

此前的多项研究着重描述氯离子在混凝土孔隙网络中的侵入过程。根据菲克扩散定律，可以用闭式方程简单描述氯离子侵入混凝土的过程 [2, 27]。研究者提出了先进的有限元方法，以捕捉氯离子侵入过程中涉及的多种相互作用现象 [28, 17, 18, 29, 5]。此类数值方法的潜在局限在于，问题设定本身涉及多种相互作用的物理机制，耦合求解过程往往会产生巨大的计算开销 [29, 5]。

鉴于上述局限性，一些研究已致力于基于机器学习（ML）算法开发代理框架，以描述混凝土中氯离子的演化。开展此类工作的主要动机在于，基于物理的建模方案需要投入大量计算资源，其

*通讯作者mojtaba@austin.utexas.edu (M. Aliasghar-Mamaghani);mohammad.khalafi85@sharif.edu(M. Khalafi)

最终目标是提供一种经济高效的方法 [30–36]。

过去已采用多种方法。简化方法主要着重于量化闭式解中涉及的氯离子扩散系数 [32, 30, 34, 31, 33]。研究人员也考察了物理机制引导的方法再现氯离子含量的能力 [35]。近期进展进一步表明，若干机器学习算法能够准确再现混凝土中的氯离子含量，同时考虑多种相互作用的现象 [36]。

以往绝大多数研究都聚焦于该问题的某个孤立方面，尤其着重于确定闭式解所涉及的扩散系数。鉴于问题本身的复杂性，机器学习技术很少用于研究氯离子随时间的演化。混凝土配合比组成与氯离子随时间的演化之间的相关性，是另一个受到关注有限的重要方面。这一点至关重要，因为它直接关系到土木基础设施在极端环境中的使用寿命。鉴于人们日益关注气候变化和结构老化对严酷环境中结构使用寿命的影响，开展此类研究的需求愈发迫切。掌握这类知识可显著加深对混合料性质的理解，从而优化其性能，并进一步为设计韧性强且耐久的土木基础设施提供依据。

为满足上述研究需求，本研究采用多种独立机器学习算法来描述混凝土中氯离子随时间的演化。该方法包括三种简单的机器学习算法，即线性回归、K近邻回归和核岭回归，以及四种更为复杂的算法，包括支持向量回归、 Gaussian 过程回归器和两类人工神经网络，即前馈网络（即多层感知机，MLP）和门控循环单元。后者主要用于研究序列响应。数据集中包含范围广泛的混凝土配合比特性以及各种环境因素。研究对这些算法的准确性进行了评估。进一步分析阐明了混合料组成对氯离子随时间演化的影响，以及这些特征在严酷环境下延长土木基础设施使用寿命方面所发挥的作用。

2. 算法描述

模型的开发由多种独立机器学习算法驱动，包括三种相对简单的方法和四种更为复杂的方法，旨在识别氯离子随时间的演化与混凝土配合比特性之间的隐含相关性。采用多种机器学习算法的主要动机在于评估每个模型的能力并增强对底层隐含相关性进行无偏预测的信心。

第一类算法是线性回归（LR）方法。该算法通过建立输入特征与输出之间的线性关系，对目标变量进行简单估计。该模型所涉及的参数采用最小二乘法进行估计，其目标是最小化残差平方和 [37]。

所考虑的第二种简单算法基于 k近邻（KNN）回归。该方法是一种非参数、基于实例的学习回归器，它利用特征空间中的k 个点（最近邻）来预测输出。在本研究中，预测值通过对这些邻居进行加权平均得到 [38, 37]。

核岭回归（KRR）是本研究采用的另一种机器学习算法。该方法基于岭回归，并利用核技巧将输入特征隐式映射到高维空间。岭回归部分引入惩罚参数，以防止过拟合，并通过缩小系数来提升泛化能力 [39, 37]。

支持向量回归（SVR）是人工智能领域众多方向中常用的机器学习算法。核岭回归（KRR）和 SVR 均基于核的学习框架，其中采用核函数在高维特征空间中建立相关性；然而，两者的损失函数和优化目标各不相同。本研究采用的 SVR 形式为 ϵ-SVR 模型，该模型允许误差处于 ϵ-不敏感管内，同时对超出该区域的偏差进行惩罚 [40–42]。

高斯过程回归（GPR）是本研究采用的另一类算法，属于非参数贝叶斯模型，同样运用核技巧来刻画潜在模式。该模型的构建基于以下假设：在特征空间中评估的潜在函数值服从联合高斯分布。高斯过程回归进一步在预测中纳入一个独立的噪声项，该噪声项被建模为高斯随机变量，通常具有零均值。本研究采用的核函数为径向基函数 [43, 44]。

最后一类算法依赖人工神经网络（ANN）。ANN 最初受到生物神经网络的启发，旨在重现类似人类的表现 [45, 46]。本研究考察的第一种 ANN 是多层感知机（MLP），其目标是捕捉输入特征与输出特征之间相当复杂的关系。MLP 是前馈神经网络的一个子类，其架构可使信息沿前向传播。该架构由多个层构成，每层包含大量神经元，并通过加权突触连接彼此相连。每个神经元都包含一个计算单元，用于接收来自前一层的输入，随后通常经由激活函数运算产生输出。该算法通常通过采用梯度下降方案进行优化的反向传播过程来训练。该

过程作用于与突触连接相关的权重因子，以提高网络的效率。

常用多层感知机算法的架构本质上不具备显式处理序列建模的能力。因此，本研究采用的最后一种先进机器学习算法基于门控循环单元（GRU）[47]。GRU 是循环神经网络（RNN）的一个子类，借助门控机制自适应地捕捉时间依赖关系，同时缓解传统 RNN 的一些缺陷，例如梯度消失问题。本研究采用 GRU 的动机源于数据集中固有的时间依赖关系。

3. 数据集与模型开发 t

本研究采用的数据集基于文献中对混凝土试件开展的实验测试 [48–50、17、51–55]，可通过在线存储库获取 [56]。本研究主要关注扩散，而忽略平流。在此方面，该数据集中不包含任何驱动力由水分流动（平流）控制的实验实例。这一假设对现有数据集的影响是 [56, 36] 排除水分驱动数据（平流），仅关注浓度梯度驱动数据（扩散）。采用这一假设旨在提高结果的可靠性，并避免任何可能由平流引起的误差。

所分析的数据集包含一系列环境因素和混合料性质，构成了输入变量与输出变量的清单。在本研究中，关注的量是混凝土孔隙网络中的氯离子含量。输入变量清单包括表面氯离子含量、暴露时间、温度以及距暴露表面的深度等环境因素，同时还包括混凝土混合料的组成，即水、抗硫酸盐波特兰水泥（SPRC）、普通波特兰水泥（OPC）、水胶比、粉煤灰（FA）、硅灰（SF）、磨细粒化高炉矿渣（GGBS）、高效减水剂以及细骨料和粗骨料的含量。

模型的开发与框架的实现依托于文献中成熟的库 [40, 57]。训练过程包括将数据集划分为训练集和测试集，比例分别为 0.75 和 0.25。随后，对数据集进行归一化处理，使其均值为 0、标准差为 1.0。之后，微调过程采用 10折交叉验证，以降低过拟合的可能性。

采用多种指标评估机器学习算法的性能，包括决定系数（R^2）、平均绝对误差（MAE）、均方误差（MSE）及其平方根（RMSE），以及平均绝对百分比误差（MAPE）。决定系数越接近 1，性能越好；而其他指标的数值越接近 0，结果越理想。

4. 结果

各机器学习算法的预测能力汇总于图 1。考虑到各学习器的特点，正如预期，线性回归（LR）的估计效果较差，性能指标为 $R^2 = 0.62$。k近邻（KNN）回归的估计效果相对令人满意，其相应的 R^2得分为0。89 和 0。82，分别对应训练集和测试集划分。

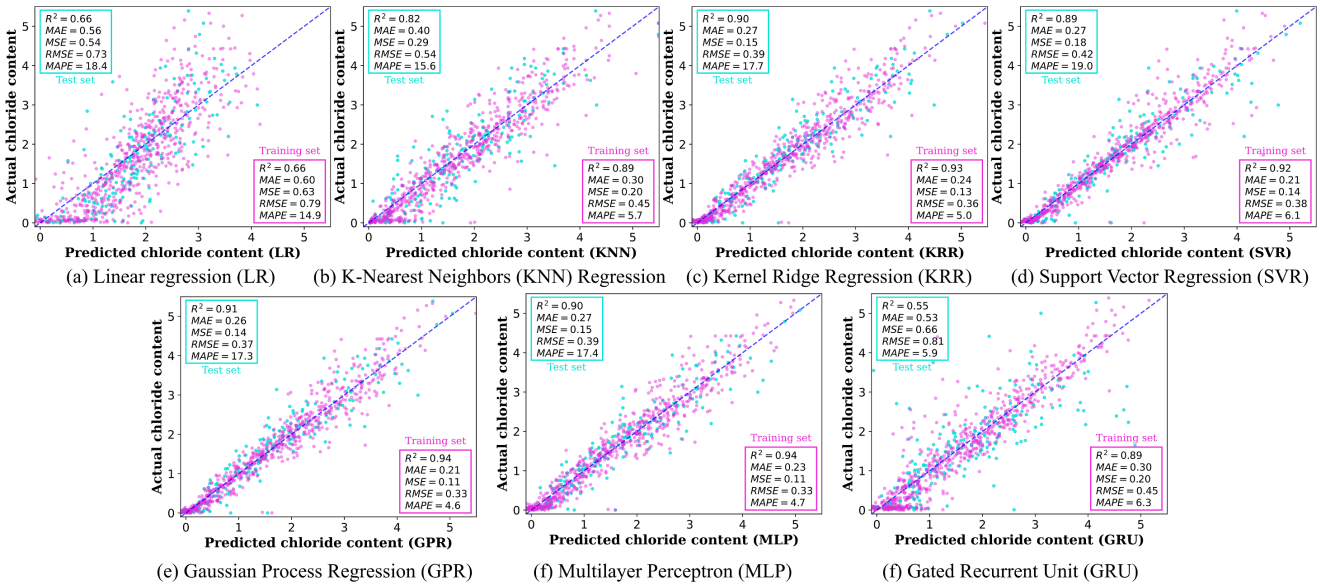
核岭回归（KRR）和支持向量回归（SVR）表现出良好的预测性能，其相应测试集 R^2 得分分别为0.90和0.89。高斯过程回归（GPR）提供了准确的估计，其测试集得分为 $R^2 = 0.91$。

随后，针对所采用的人工神经网络，多层感知机（MLP）表现良好，测试集得分为 $R^2 = 0.90$。另一方面，门控循环单元（GRU）表现不佳，得分为 $R^2 = 0.55$。

在建立模型并评估其预测氯离子含量的准确性后，进一步研究混凝土配合比组成对氯离子随时间的演化的敏感性。鉴于上述评估指标和所达到的准确性，GRU被从后续分析所用的机器学习学习器清单中剔除。

通过考察混凝土配合比组分与时空域之间的相关性，阐明了混凝土配合比特性对混凝土中氯离子随时间演变的影响。研究以参考混凝土混合料为基准 [53]，通过将各参数在数据集 [56]中观测到的整个范围内逐一变化，评估各项混合料性质的单独影响。参考混凝土混合料由 184 kg/m^3 水、460 kg/m^3 普通波特兰水泥、100 kg/m^3 粉煤灰，以及分别为 700 和 1050 kg/m^3，的细骨料和粗骨料组成，高效减水剂含量为 1.8 kg/m^3。试件在平均环境温度为 9 ℃ [53]的条件下，暴露于表面氯离子浓度为 19.6 gr/l 的环境中，持续 1.3 年。除非另有说明，时间变化图的参考点固定在距暴露表面 10 mm 处。

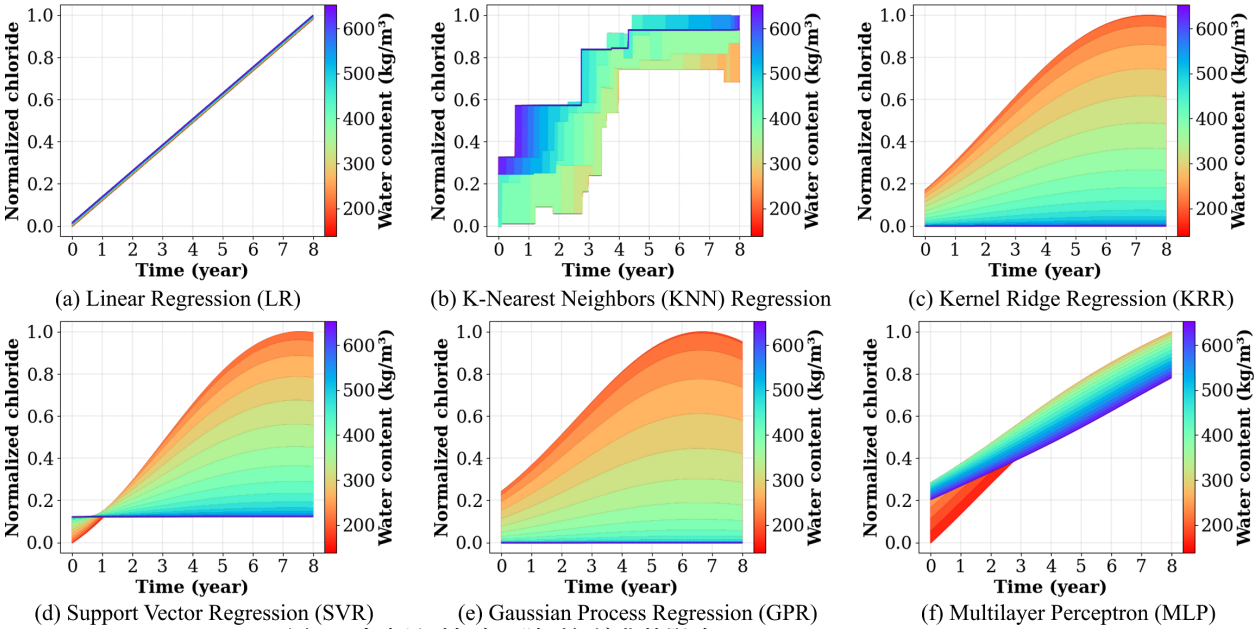
图 2 展示了在暴露表面以下 10 mm 处，采用各种机器学习算法分析混凝土混合料含水量对氯离子随时间演化的影响。鉴于 LR 算法较为简单，LR 方法捕捉到的是线性响应。K近邻算法也对总体趋势进行了简单表征，而其他方法则揭示出更清晰的规律。总体而言，LR、K近邻和多层感知机算法的结果表明，含水量增加会使氯离子浓度随时间升高；而采用核岭回归、支持向量回归和高斯过程回归算法时，则观察到相反的关系。尽管不同算法得出的关系并不一致，但考虑到问题的物理机制，正相关似乎更为合理。



(a) Linear regression (LR) (b) K-Nearest Neighbors (KNN) Regression (c) Kernel Ridge Regression (KRR) (d) Support Vector Regression (SVR)

(e) Gaussian Process Regression (GPR) (f) Multilayer Perceptron (MLP) (f) Gated Recurrent Unit (GRU)

图1： 所采用机器学习算法的评估指标



(a) Linear Regression (LR) (b) K-Nearest Neighbors (KNN) Regression (c) Kernel Ridge Regression (KRR)

(d) Support Vector Regression (SVR) (e) Gaussian Process Regression (GPR) (f) Multilayer Perceptron (MLP)

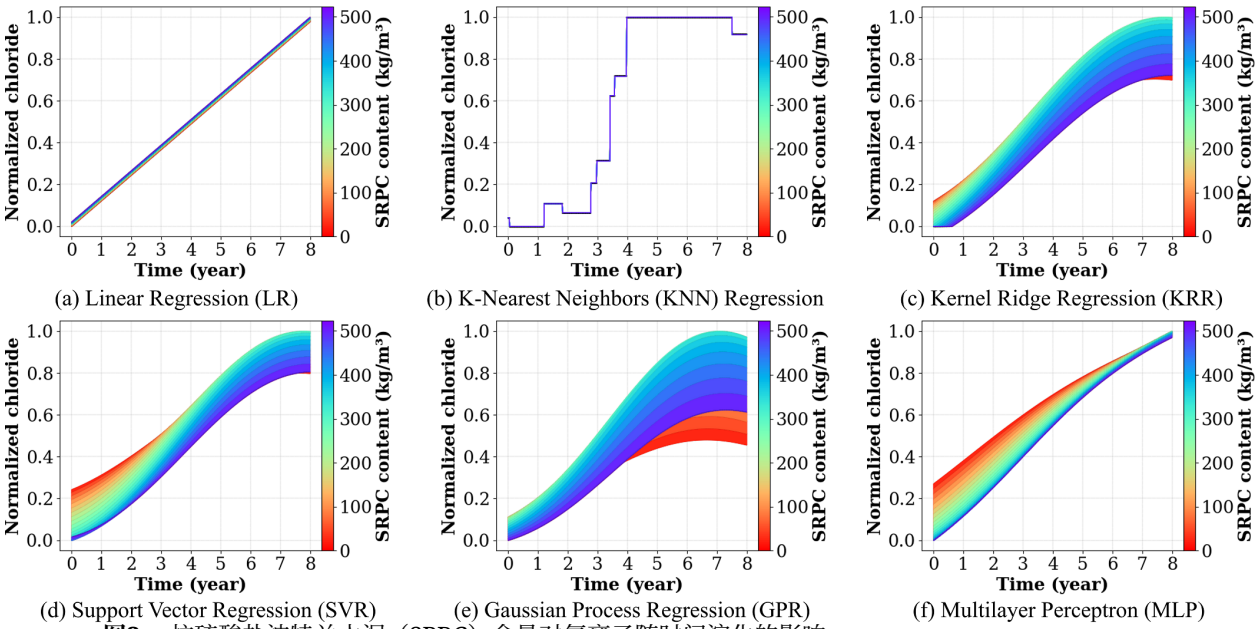
图2： 含水量对氯离子随时间演化的影响

图中展示了结果对抗硫酸盐波特兰水泥（SPRC）含量的敏感性 3。考虑到各机器学习学习器的预测能力，多层感知机呈现出相对清晰的趋势：SPRC 含量增加会使氯离子含量随时间降低。核岭回归、支持向量回归和高斯过程回归算法在一定程度上也呈现出类似趋势，表明氯离子随时间的演化与 SPRC 含量之间存在负相关关系。

普通硅酸盐水泥（OPC）含量与氯离子随时间的演化之间的相关性如图4所示。与先前的观察结果类似，线性回归和K近邻模型对总体趋势进行了简单估计，而核岭回归和高斯过程回归模型则呈现出更清晰的趋势。就此而言，OPC含量增加会降低氯离子浓度。

图5 展示了水胶比对氯离子随时间演化的影响。简化的机器学习学习器只能对该参数进行粗略估计。先进模型则能更清晰地呈现总体趋势；然而，这一趋势似乎会随时间交替变化。总体而言，在最初几年，氯离子含量与水胶比呈直接相关，之后则转为负相关。

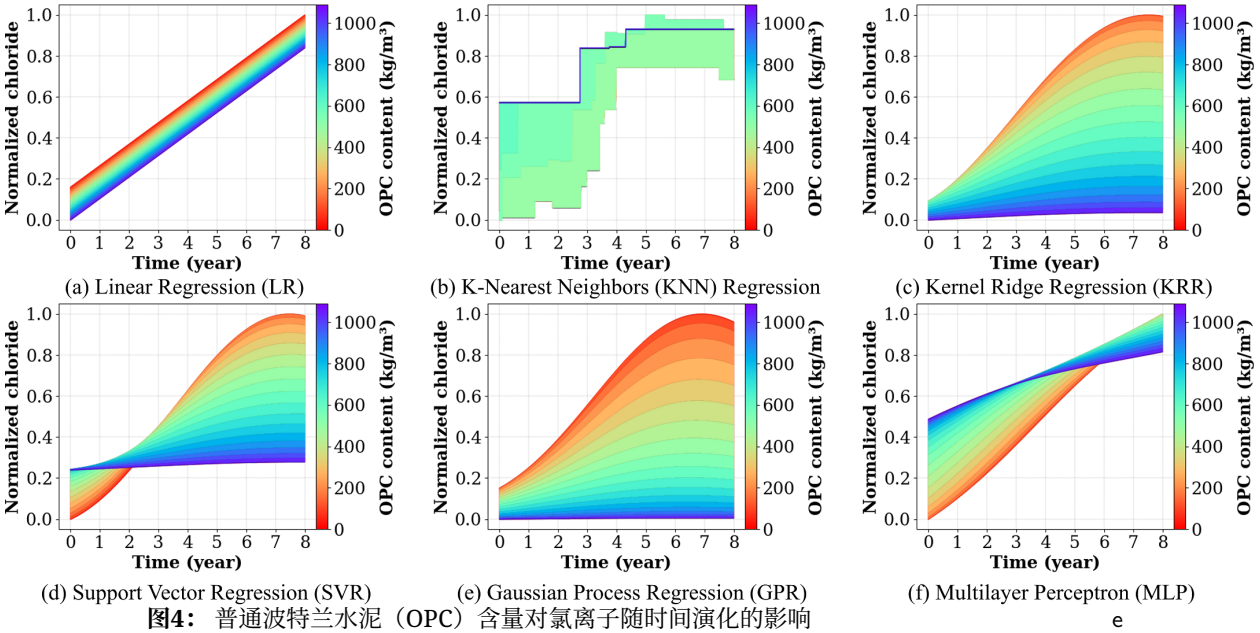
粉煤灰（FA）含量对氯离子随时间的演化的影响如图所示6。所有先进机器学习算法的模型响应对这一参数的敏感性总体相似。核岭回归、支持向量回归和高斯过程回归模型中的这种关系尤为明显，它们



(a) Linear Regression (LR) (b) K-Nearest Neighbors (KNN) Regression (c) Kernel Ridge Regression (KRR)

(d) Support Vector Regression (SVR) (e) Gaussian Process Regression (GPR) (f) Multilayer Perceptron (MLP)

图3： 抗硫酸盐波特兰水泥（SPRC）含量对氯离子随时间演化的影响



(a) Linear Regression (LR) (b) K-Nearest Neighbors (KNN) Regression (c) Kernel Ridge Regression (KRR)

(d) Support Vector Regression (SVR) (e) Gaussian Process Regression (GPR) (f) Multilayer Perceptron (MLP)

图4： 普通波特兰水泥（OPC）含量对氯离子随时间演化的影响

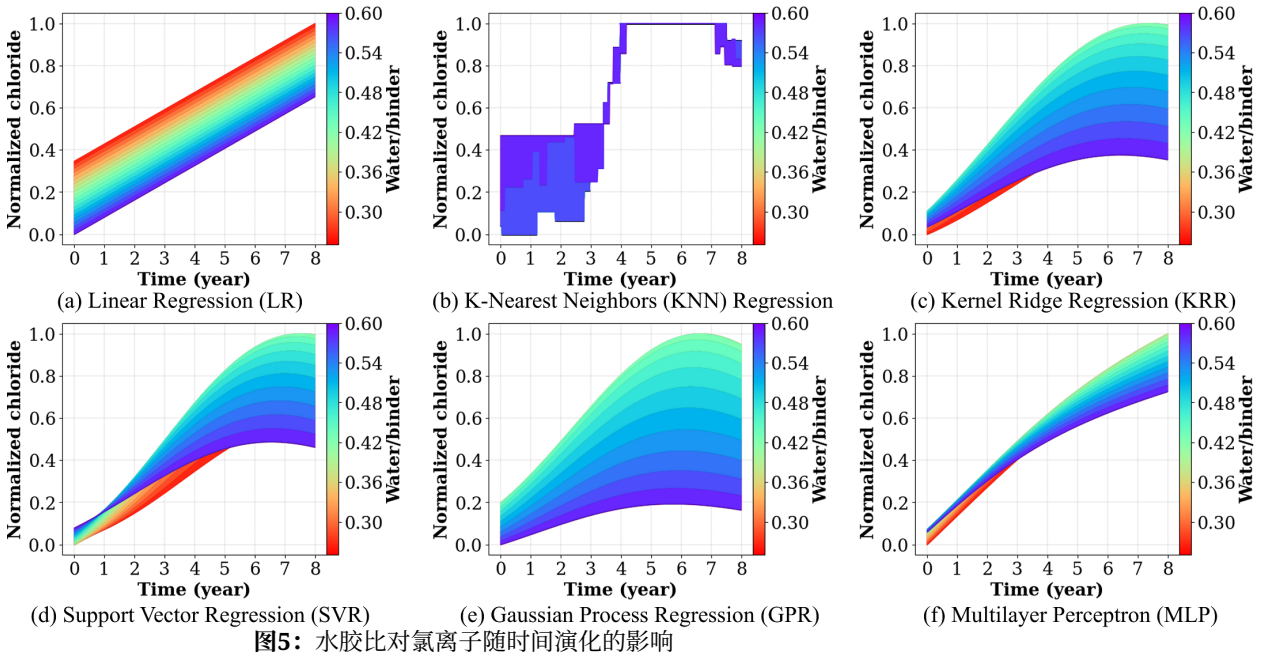
e

显示出负相关关系，即粉煤灰含量增加会导致氯离子浓度降低。

图7展示了硅灰（SF）含量与氯离子浓度随时间变化之间的相关性。在机器学习算法中，KRR、GPR 和 MLP 模型捕捉到了整体响应的明显趋势。随着硅灰含量增加，混凝土中的氯离子浓度降低。根据图中结果，最佳性能对应于 SF 含量最高的情况，这代表了最有效的使用寿命提升配置。

图 8展示了结果对磨细粒化高炉矿渣（GGBS）含量的敏感性。与此前的观察结果一致，核岭回归和高斯过程回归清晰地呈现了模型响应。总体而言，GGBS 含量较高与氯离子浓度随时间变化之间存在负相关关系：前者显著增加会导致后者降低；然而，从图中可以看出，氯离子浓度对 GGBS 含量高度敏感，即使含量相对较低，也会对氯离子浓度随时间的变化产生显著影响。支持向量回归也呈现出类似趋势，多层感知机在一定程度上亦是如此。

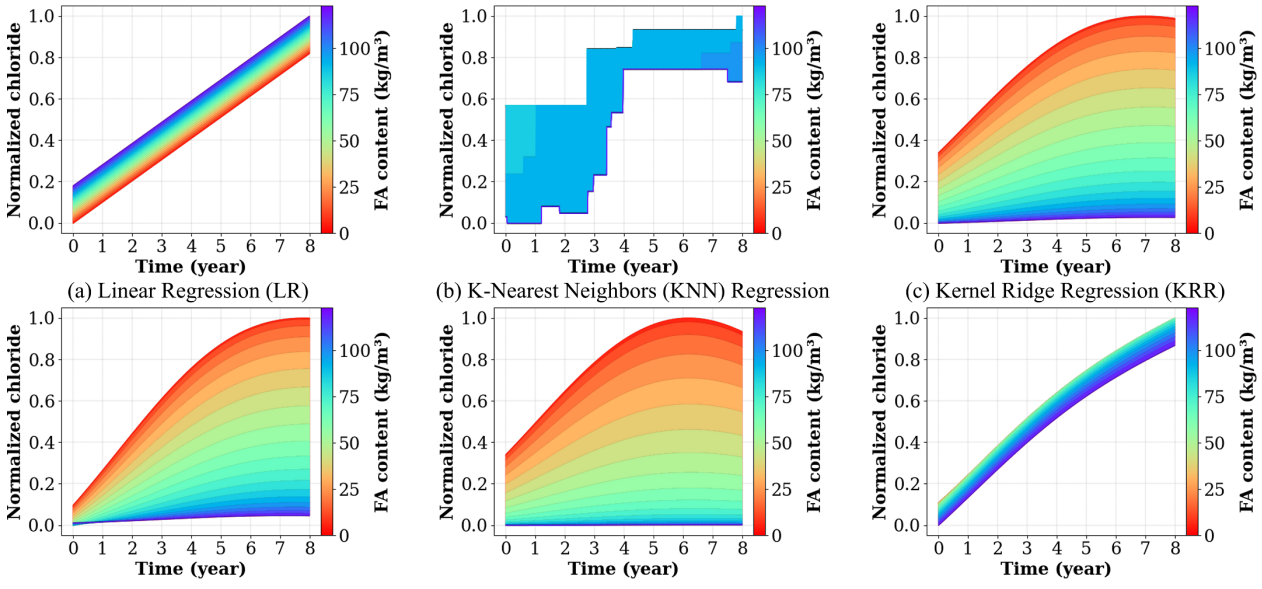
图9 展示了固定时间点下高效减水剂对氯离子浓度的影响。在所采用的机器学习算法中，高斯过程回归模型呈现出一致的趋势，而其他学习器（支持向量回归、核岭回归和多层感知机）的响应则随时间波动。在这方面，高斯过程回归预测出负相关关系，而多层感知机则表现出相对直接的相关性。核岭回归的响应



(a) Linear Regression (LR) (b) K-Nearest Neighbors (KNN) Regression (c) Kernel Ridge Regression (KRR)

(d) Support Vector Regression (SVR) (e) Gaussian Process Regression (GPR) (f) Multilayer Perceptron (MLP)

图5：水胶比对氯离子随时间演化的影响



(a) Linear Regression (LR) (b) K-Nearest Neighbors (KNN) Regression (c) Kernel Ridge Regression (KRR)

(d) Support Vector Regression (SVR) (e) Gaussian Process Regression (GPR) (f) Multilayer Perceptron (MLP)

图6：粉煤灰（FA）含量对氯离子随时间演化的影响

在一定程度上也与高斯过程回归随时间呈现的趋势一致。

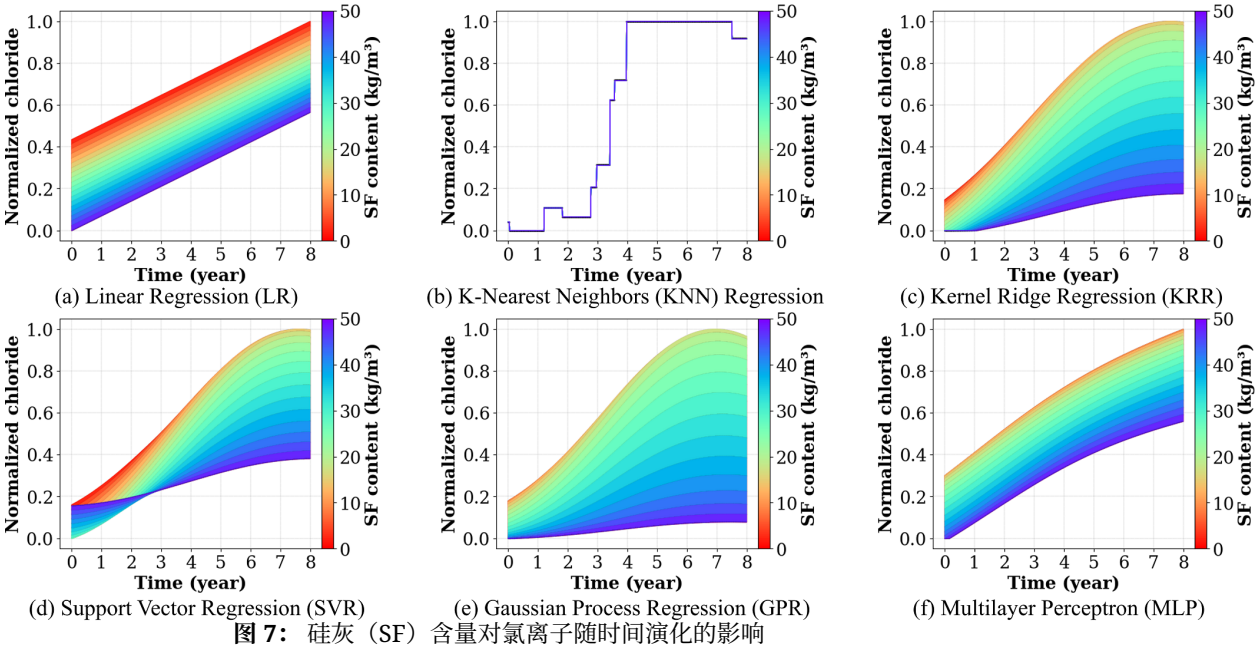
进一步研究了细骨料与氯离子含量之间的相关性，如图10所示。在所采用的机器学习算法中，KRR、SVR 和 GPR 得出的响应较为相似。总体而言，细骨料含量增加会降低氯离子浓度随时间的变化。然而，响应对具体的骨料含量较为敏感。尤其是，细骨料含量较低时，MLP 的响应更为明显。综合各种响应来看，在所采用的范围内似乎存在一个最佳细骨料含量，可带来最理想的响应。

随后，图中展示了粗骨料含量与氯离子浓度之间的相关性 11。

在所有机器学习算法中，KRR、高斯过程回归和多层感知机模型清晰地揭示了其内在关系：随着粗骨料含量增加，氯离子浓度也会随时间相应升高。然而，存在一个特定含量——略低于本研究采用的最大值——会形成最不利的混合料，导致氯离子浓度最高。另一方面，耐久性的最佳值对应于最低的粗骨料含量。

5. 讨论

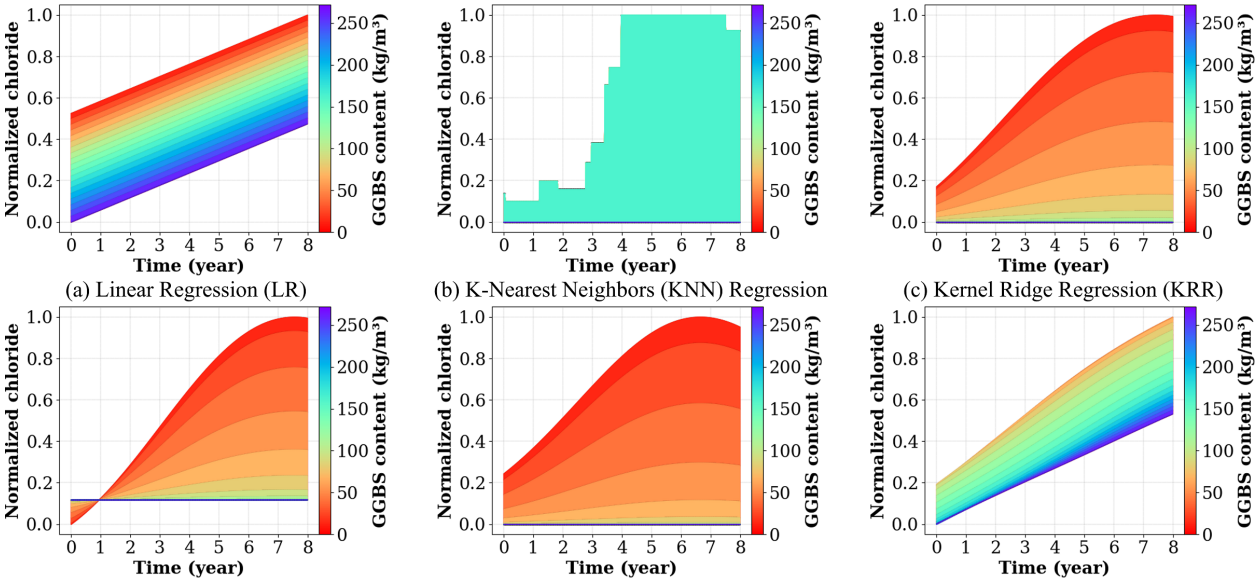
采用多种机器学习算法成功描述了混凝土中氯离子的演变过程。多层感知机的结果最为准确，训练和



(a) Linear Regression (LR) (b) K-Nearest Neighbors (KNN) Regression (c) Kernel Ridge Regression (KRR)

(d) Support Vector Regression (SVR) (e) Gaussian Process Regression (GPR) (f) Multilayer Perceptron (MLP)

图 7： 硅灰（SF）含量对氯离子随时间演化的影响



(a) Linear Regression (LR) (b) K-Nearest Neighbors (KNN) Regression (c) Kernel Ridge Regression (KRR)

(d) Support Vector Regression (SVR) (e) Gaussian Process Regression (GPR) (f) Multilayer Perceptron (MLP)

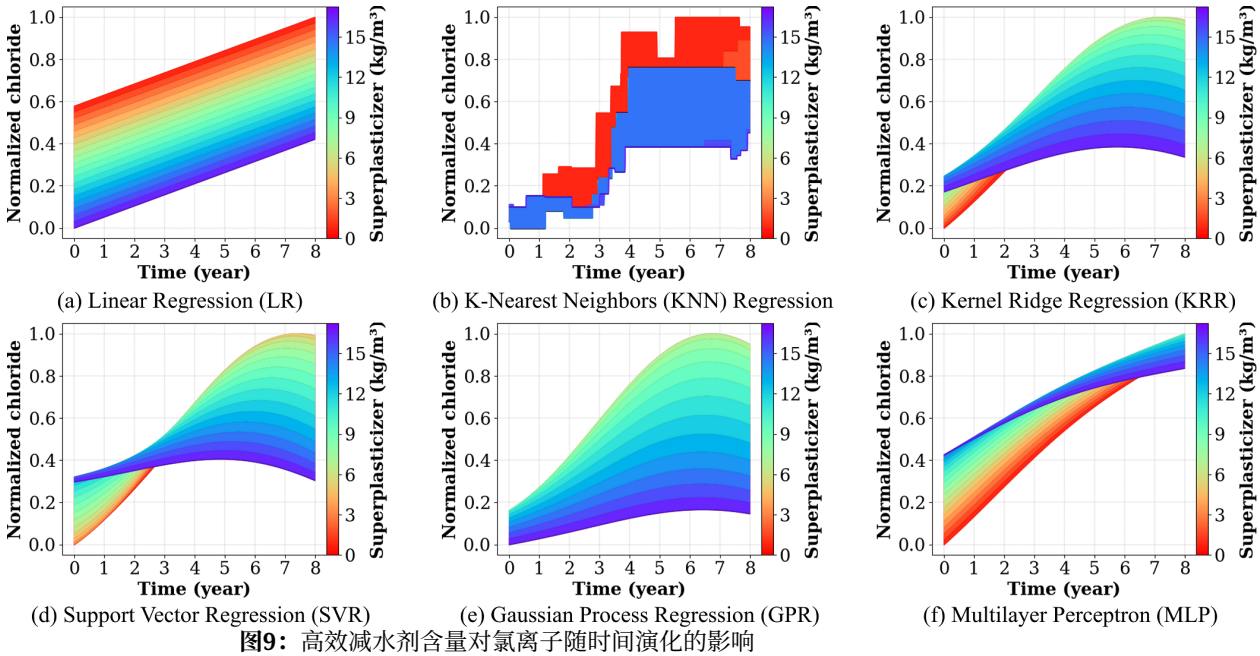
图 8： 粒化高炉矿渣粉（GGBS）含量对氯离子随时间演化的影响

测试得分分别为 $R^2 = 0.94$ 和 $R^2 = 0.90$。准确度最低的方法分别是门控循环单元和线性回归算法。

关于门控循环单元（GRU）网络的准确性，有一项重要观察。如前文所述，该方法的基本前提在于其再现序列数据的能力。尽管训练集取得了令人满意的表现，得分为 $R^2 = 0.89$，但测试集的准确性较差（$R^2 = 0.55$）。这一差异表明，数据中存在的序列依赖性对模型构成了显著限制，从而削弱了其预测准确性。训练和测试中的挑战可能与数据集中所采用的混凝土混合料配比的多样性有关。

关于混凝土组分与氯离子侵入之间隐藏相关性的重要观察，涉及各机器学习学习器捕捉输入特征与输出特征之间潜在关系的能力。在这方面，LR 对底层模式给出了粗略的线性估计。同样，K近邻生成的表示相当离散且不够清晰。SVR 和 MLP 捕捉到了大多数混合料组成的明显趋势，但在某些情况下，它们在时间模式上表现出变化。KRR 也给出了可接受的响应，但存在类似的局限性；而高斯过程回归在整个输入特征范围内始终产生清晰的趋势。

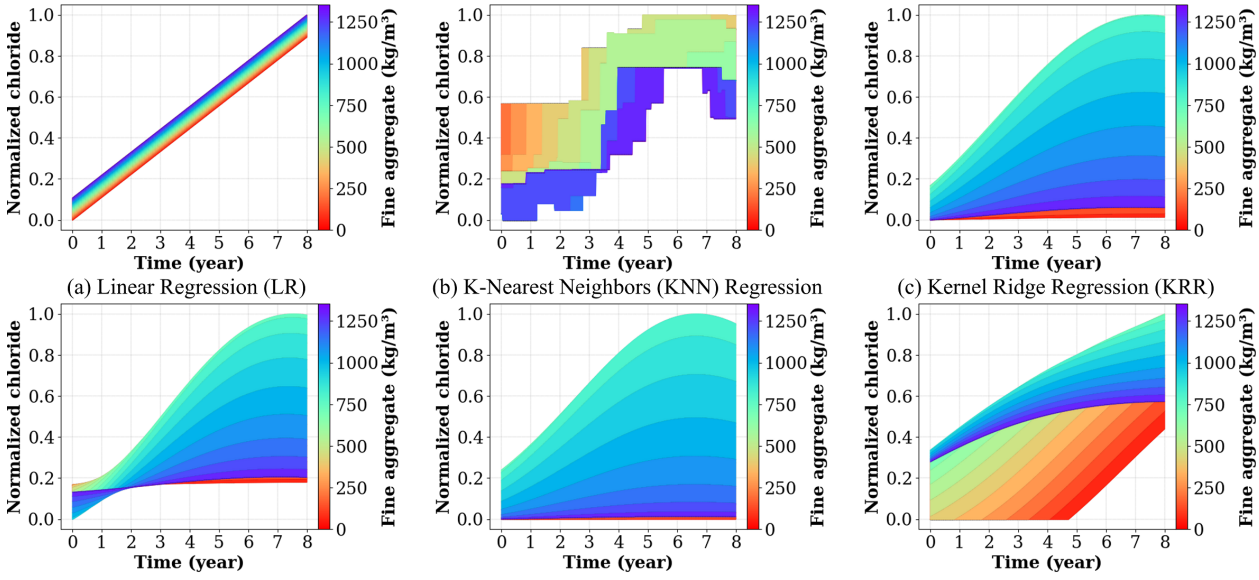
通过对所有机器学习算法进行评估，揭示了输入特征与输出特征之间隐藏的相关性。观察到氯离子随时间的演化与以下



(a) Linear Regression (LR)　(b) K-Nearest Neighbors (KNN) Regression　(c) Kernel Ridge Regression (KRR)

(d) Support Vector Regression (SVR)　(e) Gaussian Process Regression (GPR)　(f) Multilayer Perceptron (MLP)

图9： 高效减水剂含量对氯离子随时间演化的影响



(a) Linear Regression (LR)　(b) K-Nearest Neighbors (KNN) Regression　(c) Kernel Ridge Regression (KRR)

(d) Support Vector Regression (SVR)　(e) Gaussian Process Regression (GPR)　(f) Multilayer Perceptron (MLP)

图10： 细骨料含量对氯离子随时间演化的影响

若干混凝土配合比组成呈反向关系，包括抗硫酸盐波特兰水泥、普通波特兰水泥、粉煤灰、硅灰和高效减水剂。细骨料含量也呈现出类似趋势。相反，氯离子含量与粗骨料含量之间存在明显的直接相关性，即后者增加会导致前者增加。氯离子含量与含水量及水胶比之间的相关性不太明确，且随时间交替变化；然而，在暴露早期，MLP 显示这些特征总体上与氯离子含量呈直接相关。氯离子的演化对磨细粒化高炉矿渣（GGBS）高度敏感，其用量的微小变化会导致氯离子含量发生显著变化。

一个值得注意的方面是对所观察到现象的物理解释。虽然所采用的机器学习算法有助于揭示输入特征与输出特征之间的关系，但仍需进一步研究支配这些现象的物理机制，这也构成了未来的研究课题。在这方面，所观察到的某些趋势可能部分归因于混凝土孔隙形态随时间的变化。例如，粗骨料含量增加可能导致整体孔隙率升高，进而促进氯离子扩散。相反，增加粉煤灰含量可以降低混凝土孔隙率，从而减缓氯离子随时间的扩散。此外，与混合料组成相关的次级化学反应可能会影响氯离子侵入的时间演变。A

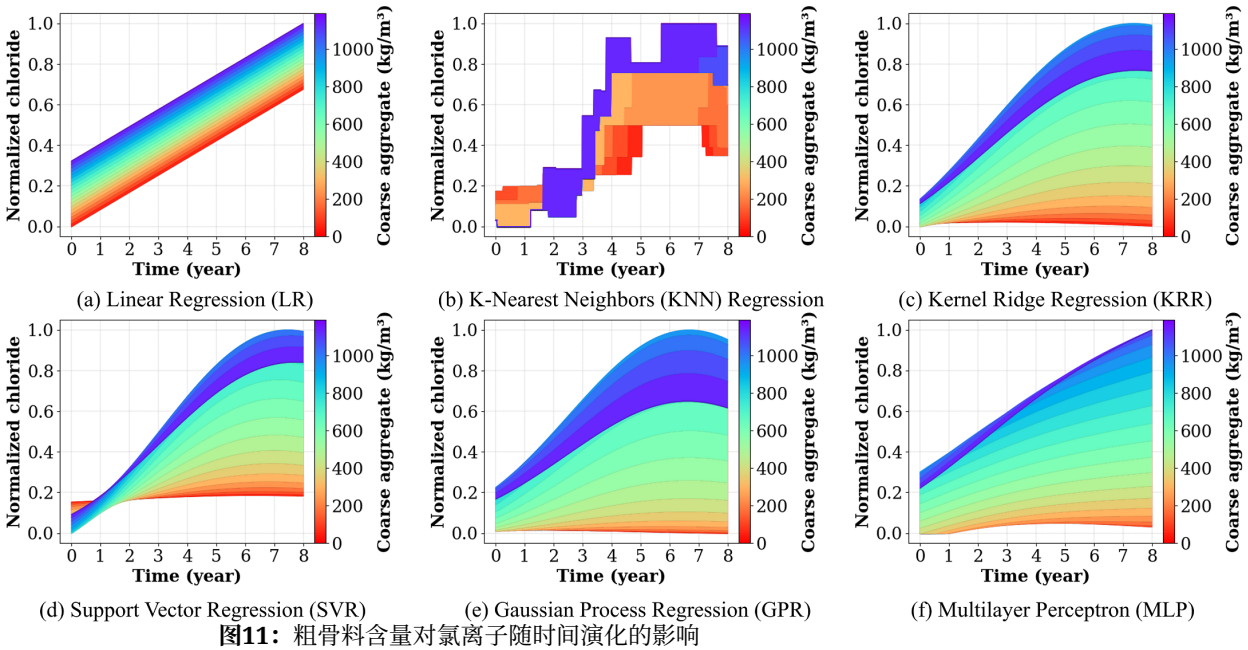


图11：粗骨料含量对氯离子随时间演化的影响

对这些机制的详细研究超出了本研究的范围，将留待未来开展。

借助多种机器学习算法，成功揭示了隐含相关性。然而，优化混凝土配合比是未来研究的一个有趣方向。目前，这类研究可能面临挑战，原因在于文献中可用的实验测量数量有限，而且输入特征与时空域之间存在复杂的耦合作用。

6. 结论

本研究采用多种机器学习（ML）算法，评估混凝土配合比组成对混凝土结构中氯离子侵入的影响。所采用的独立机器学习算法包括三种简单方法和四种复杂方法。简单算法包括线性回归（LR）、k近邻（KNN）回归和核岭回归（KRR）。复杂算法包括支持向量回归（SVR）、高斯过程回归（GPR），以及两类人工神经网络：多层感知机（MLP）和门控循环单元（GRU）。KRR、GPR和MLP算法成功预测了混凝土中的氯离子含量，测试集得分最低为 $R^2 = 0.90$。GRU未能准确捕捉测试集中的序列响应，尽管其在训练集上取得了良好得分。研究评估了输入特征与氯离子随时间的演化之间的潜在关系。LR和KNN算法提供了粗略估计，而SVR、MLP和KRR则给出了可接受且可解释的响应。另一方面，GPR表现最为出色，捕捉到了清晰且可解释的趋势。研究发现，氯离子含量与多种混合料组成之间存在明显的负相关，包括抗硫酸盐波特兰水泥、普通波特兰水泥、粉煤灰、硅灰和高效减水剂的含量，以及程度较轻的细骨料含量。相比之下，粗骨料含量与氯离子侵入之间存在明显的正相关。研究结果对磨细粒化高炉矿渣的含量较为敏感。这些发现强调了采用代理方法描述混凝土中氯离子侵入的基本意义，同时揭示了其中的潜在相关性，最终目标是延长土木基础设施的使用寿命。

CRediT 作者贡献声明

MojtabaAliasghar-Mamaghani： 撰写——审阅与编辑、撰写——初稿、软件、方法学、调查、形式分析、概念构思。**Moham- madreza Khalafi：** 撰写——审阅与编辑、撰写——初稿、软件、方法学、调查、形式分析、概念构思。

利益冲突声明

作者声明，他们不存在已知的可能影响本文所报告工作的竞争性财务利益或个人关系。

参考文献

[1] Z. P. Bažant，混凝土海洋结构中钢筋腐蚀的物理模型——理论，《结构分部期刊》105 (6) (1979) 1137–1153。[2] E. J. Hansen, V. E. Saouma，钢筋混凝土劣化的数值模拟——第一部分：氯离子扩散，《美国混凝土学会材料期刊》96 (1999) 173–180。[3] R. E. Weyers，M. G. Fitch，E. P. Larsen，I. L. Al-Qadi，W. Chamberlin，P. Hoffman，《混凝土桥梁防护与修复：化学和物理技术。使用寿命估算》，技术报告（1994）。

[4] U. M. Angst，氯离子暴露环境下钢筋混凝土结构腐蚀起始时间的预测，《水泥与混凝土研究》115 (2019) 559–567。[5] M. Aliasghar-Mamaghani，《预应力混凝土桥梁主梁中氯离子诱发腐蚀损伤的计算模拟》，博士学位论文，弗吉尼亚理工大学（2023）。[6] J. Rodriguez，L. Ortega，J. Casal，腐蚀钢筋混凝土结构的承载力，《建筑与建材》11 (4) (1997) 239–248。[7] J. Cairns，G. A. Plizzari，Y. Du，D. W. Law，C. Franzoni，腐蚀损伤钢筋的力学性能，《美国混凝土学会材料期刊》102 (4) (2005) 256。[8] T. M. Pape，R. E. Melchers，腐蚀对使用45年的预应力混凝土桥梁梁体的影响，《结构与基础设施工程》7 (1-2) (2011) 101–108。[9] A. O. S. Solgaard，A. Michel，M. Geiker，H. Stang，钢筋均匀腐蚀导致的混凝土保护层开裂，《材料与结构》46 (11) (2013) 1781–1799。[10] F. Vecchi，L. Franceschini，F. Tondolo，B. Belletti，J. S. Montero，P. Minetola，自然腐蚀预制混凝土梁中预应力钢绞线的腐蚀形貌，《建筑与建材》296 (2021) 123720。[11] S. Habibi，A. C. Ferche，F. J. Vecchio，腐蚀损伤钢筋混凝土构件的建模，《美国混凝土学会结构期刊》119 (1) (2022) 169–182。[12] M. Aliasghar-Mamaghani，I. Koutromanos，C. Roberts-Wollmann，M. Hebdon，预应力桥梁主梁中腐蚀引起的强度退化的分析评估，《结构工程杂志》148 (11) (2022) 04022188。[13] L. Youping，R. Weyers，氯离子污染的钢筋混凝土结构中保护层混凝土腐蚀开裂时间的建模，《美国混凝土学会材料期刊》95 (6) (1996)。[14] E. J. Hansen，V. E. Saouma，钢筋混凝土劣化的数值模拟：第二部分——钢筋腐蚀与混凝土开裂，《材料杂志》96 (3) (1999) 331–338。[15] V. E. Murray，G. C. Frantz，对使用27年的预应力混凝土桥梁梁体进行氯离子检测，《PCI期刊》37 (5) (1992) 68–79。[16] M. Aliasghar-Mamaghani，I. Koutromanos，C. Roberts-Wollmann，M. Hebdon，混凝土结构中氯离子诱发腐蚀损伤的多物理场建模，《计算机与结构》308 (2025) 107643。[17] K. Maekawa，T. Ishida，T. Kishi，融合材料与结构力学的混凝土性能多尺度建模，《先进混凝土技术杂志》1 (2) (2003) 91–126。[18] K. Maekawa，T. Ishida，T. Kishi，《结构混凝土的多尺度建模》，CRC出版社，2008。[19] R. R. Hussain，T. Ishida，氯离子与温度强耦合作用下钢筋混凝土的增强型电化学腐蚀模型，《建筑与建材》25 (3) (2011) 1305–1315。[20] M. Bazli，H. Ashrafi，A. V. Oskouei，严酷环境对GFRP拉挤型材力学性能的影响，《复合材料B辑：工程》99 (2016) 203–215。[21] M. Aliasghar-Mamaghani，A. Khaloo，GFRP筋混凝土抗弯框架的抗震性能，《复合材料B辑：工程》163 (2019) 324–338。[22] M. Aliasghar-Mamaghani，A. Khaloo，钢筋混凝土抗弯框架中FRP筋梁的有效抗弯刚度，《建筑复合材料杂志》25 (1) (2021) 04020083。[23] S. Hassanpour，A. Khaloo，M. Aliasghar-Mamaghani，H. Khaloo，受压玻璃纤维增强聚合物筋对钢筋混凝土梁抗弯性能的影响，《美国混凝土学会结构期刊》119 (6) (2022) 5–18。[24] T. A. Tran，J. W. Wallace，中等高宽比钢筋混凝土结构墙的循环试验，《美国混凝土学会结构期刊》112 (6) (2015) 653。[25] M. Aliasghar，I. Koutromanos，J. Murcia-Delso，循环荷载作用下钢筋混凝土结构墙的试验测试（2024）。

[26] M. Aliasghar-Mamaghani、A. Albright、I. Koutromanos、J. Murcia-Delso、C. Brandetsas、M. Panagiotou，采用和未采用纤维增强聚合物加固的非延性钢筋混凝土墙试验测试，第18届世界地震工程会议（WCEE18），在线会议论文集……，2024年。[27] M. Collepardi、A. Marcialis、R. Turriziani，氯离子在水泥浆体和混凝土中的渗透，《美国陶瓷学会志》55（10）（1972）534–535。[28] A. V. Saetta、R. V. Scotta、R. V. Vitaliani，部分饱和混凝土中的氯离子扩散分析，《材料杂志》90（5）（1993）441–451。[29] M. Aliasghar-Mamaghani、I. Koutromanos、C. Roberts-Wollmann、M. Hebdon，考虑使用寿命环境条件的预应力混凝土桥梁主梁氯离子侵入有限元分析，《结构工程学报》149（11）（2023）04023156。[30] R. Cai、T. Han、W. Liao、J. Huang、D. Li、A. Kumar、H. Ma，利用集成机器学习预测海洋环境混凝土的表面氯离子浓度，《混凝土研究》136（2020）106164。[31] W. Z. Taffese、L. Espinosa-Leal，一种预测混凝土氯离子迁移系数的机器学习方法，《建筑与建材》348（2022）128566。[32] M. Hosseinzadeh、S. S. Mousavi、A. Hosseinzadeh、M. Dehestani，利用综合数据集预测混凝土抗氯离子性能的高效机器学习方法，《科学报告》13（1）（2023）15024。[33] W. Zheng、J. Cai，基于不同机器学习方法的机制砂混凝土氯离子扩散系数最优预测模型，《建筑与建材》411（2024）134414。[34] V. Q. Tran，含辅助胶凝材料混凝土氯离子扩散系数研究的机器学习方法，《建筑与建材》328（2022）127103。[35] W. M. Shaban、K. Elbaz、A. Zhou、S.-L. Shen，用于混凝土氯离子扩散建模的物理信息深度神经网络，《人工智能工程应用》125（2023）106691。[36] M. Aliasghar-Mamaghani、I. Koutromanos、M. Hebdon、C. Roberts-Wollmann，使用机器学习算法定量描述混凝土中的氯离子侵入，《建筑与建材》467（2025）140209。[37] J. Friedman，《统计学习要素：数据挖掘、推断与预测》，（无标题）（2009）。[38] E. Fix，《判别分析：非参数判别及一致性性质》，第1卷，美国空军航空医学学校，1985年。[39] R. Tibshirani，通过套索回归实现回归收缩与选择，《英国皇家统计学会学报B辑：统计方法学》58（1）（1996）267–288。[40] F. Pedregosa、G. Varoquaux、A. Gramfort、V. Michel、B. Thirion、O. Grisel、M. Blondel、P. Prettenhofer、R. Weiss、V. Dubourg等，Scikit-learn：Python中的机器学习，《机器学习研究杂志》12（2011）2825–2830。[41] S. Haykin，《神经网络与学习机器》，第3版，培生教育印度，2009年。[42] A. J. Smola、B. Schölkopf，支持向量回归教程，《统计与计算》14（3）（2004）199–222。[43] C. E. Rasmussen，机器学习中的高斯过程，载于：《机器学习暑期学校》，Springer，2003年，第63–71页。[44] E. Schulz、M. Speekenbrink、A. Krause，高斯过程回归教程：函数的建模、探索与利用，《数学心理学杂志》85（2018）1–16。[45] A. K. Jain、J. Mao、K. M. Mohiuddin，人工神经网络：教程，《计算机》29（3）（1996）31–44。[46] R. P. Lippmann，神经网络计算简介，《ACM SIGARCH计算机体系结构新闻》16（1）（1988）7–25。[47] K. Cho、B. Van Merriënboer、D. Bahdanau、Y. Bengio，论神经机器翻译的性质：编码器—解码器方法，arXiv预印本arXiv:1409.1259（2014）。[48] G. Sergi、S. Yu、C. Page，暴露于盐碱环境的水泥基材料中氯离子和氢氧根离子的扩散，《混凝土研究》杂志44

（158）（1992）63–69。[49] T. Maruya、Y. Matsuoka、S. Tangtermsirikul，硬化混凝土表层氯离子迁移建模，《土木学会论文集》（585）（1998）79–95。[50] T. Luping，暴露于海洋环境的混凝土中氯离子侵入——最长达10年暴露期的现场数据，2003年。[51] E. Samson、J. Marchand，水泥基材料中温度对离子传输影响的建模，《水泥与混凝土研究》37（3）（2007）455–468。[52] V. Baroghel-Bouny、M. Thiéry、X. Wang，基于性能的耐久性评估与钢筋混凝土结构使用寿命预测：作为物理模型输入数据的传输性能，《材料与结构》47（10）（2014）1669–1691。[53] J. Kim、W. J. McCarter、B. Suryanto、S. Nanukuttan、P. M. Basheer、T. M. Chrisp，海洋环境暴露混凝土中的氯离子侵入：经验模型与基于物理机制模型的比较，《水泥与混凝土复合材料》72（2016）133–145。[54] S. Pradelle、M. Thiéry、V. Baroghel-Bouny，暴露于海水中的混凝土现有氯离子侵入模型比较，《材料与结构》49（11）（2016）4497–4516。[55] B. Chen、A. G. Razaqpur，零下温度与冻结温度对混凝土中氯离子扩散和结合的影响，《建筑与建材》287（2021）123057。[56] M. Aliasghar-Mamaghani、I. Koutromanos、M. Hebdon、C. Roberts-Wollmann，使用机器学习算法定量描述混凝土中的氯离子侵入：数据集和程序（2025）。[57] A. Paszke、S. Gross、F. Massa、A. Lerer、J. Bradbury、G. Chanan、T. Killeen、Z. Lin、N. Gimelshein、L. Antiga等，PyTorch：一种命令式、高性能深度学习库，《神经信息处理系统进展》32（2019）。