

EÖTVÖS LORÁND TUDOMÁNYEGYETEM
Természettudományi Kar

ÖNÁLLÓ SZAKMAI PROJEKT

PARCIÁLIS DIFFERENCIÁLEGYENLETEK NUMERIKUS MEGOLDÁSA NEURÁLIS HÁLÓKKAL

Témavezető:
Izsák Ferenc
Egyetemi docens

Készítette:
Miskei Ferenc István
Alkalmazott Matematikus MSc



Budapest, 2021

Bevezetés

A parciális differenciálegyenletek tanulmányozása, illetve megoldása rendkívül fontos terület az alkalmazott tudományokban, mint például a fizikában, kémiában, mérnöki tudományokban. Ezeknek az egyenleteknek gyakran reménytelenül nehéz zárt alakban „megoldóképletet” találni, ezért a megoldáshoz tradicionálisan numerikus módszereket alkalmazunk. A hagyományos véges elem módszereknél egy fokkal újabb ötlet a neurális hálók ilyen célú alkalmazása, amely igen ígéretes eredményekkel kecsegtet. Várhatóan bonyolultabb egyenletek néhány pontbeli közelítő értékét kevesebb információ alapján, kisebb hibahatárral képesek meghatározni ezen eszközök [3].

Célunk ebben a projektben egy, a Laplace-egyenletre már működő programot úgy módosítani, hogy az a Poisson egyenlet megoldására is alkalmas legyen. Ez várhatóan numerikusan jóval drágább feladat, mint Laplace-egyenlet, hiszen – a Laplace-egyenlettel ellentétben – nem elegendő információt szerezni a tartomány peremén a függvényről, hanem valamilyen mérési eredményeket be kell építeni a tartomány belsejéből is ahhoz, hogy sikeresen fel tudjuk térképezni az f függvényt, és ezáltal a PDE megoldását is. A megoldóprogram szükséges módosításai után numerikus kísérleteket lesz célszerű végezni azzal kapcsolatban, hogy mennyi információt kell gyűjtenünk a tartomány határáról, illetve a belsejéből, valamint hogyan strukturáljuk a neurális hálót úgy, hogy az minél gazdaságosabban oldja meg a Poisson-egyenletet, valamint adott esetben más PDE-eket is.

1. fejezet

Problémafelvetés

Tekintsük a szokásos Laplace-egyenletet. Legyen $n \in \mathbb{N}^+$, $\Omega \subseteq \mathbb{R}^n$ összefüggő nyílt Lipschitz-tartomány, $g: \partial\Omega \rightarrow \mathbb{R}$.

$$\left. \begin{aligned} \Delta u(x) &= 0 & (x \in \Omega), \\ u|_{\partial\Omega}(x) &= g(x). \end{aligned} \right\} \quad (1.1)$$

A parciális differenciálegyenletek elméletéből ismeretes, hogy a $-\Delta$ operátorra vonatkozó alapmegoldás, vagyis a $-\Delta u = \delta_0(x)$ disztribúció értelemben vett PDE megoldása:

$$E_n(x) := \begin{cases} -\frac{1}{2\pi} \ln \|x\|_2, & \text{ha } n = 2, \\ \frac{1}{(n-2)S_n \|x\|_2^{n-2}}, & \text{ha } n \geq 3, \end{cases} \quad x \in \mathbb{R}^n \setminus \{0\}, \quad (1.2)$$

ahol S_n az n dimenziós egységgömb (hiper)felülete.

A [2] cikk működő modellt mutat arra, hogy egy nemtriviális $\Omega \subseteq \mathbb{R}^2$ tartomány néhány $\{x_1, \dots, x_I\}$ pontjára vonatkozóan (1.1) jó közelítő értékeit nyerhetjük a következő módon:

- vegyük $\partial\Omega$ néhány pontját ($\{z_1, \dots, z_K\} \subset \partial\Omega$),
- vegyük ext Ω néhány pontját $y_j \notin \bar{\Omega}, j \in \{1, \dots, J\}$
- tekintsük a $T_{y_j}(x) := E_2(x - y_j)$, Green-függvényeket, valamint
- tekintsünk ekkor egy egyrétegű, sűrű neurális hálót, amelyet az

$$\left\{ (T_{y_j}(z_1), T_{y_j}(z_2), \dots, T_{y_j}(z_K)), (T_{y_j}(x_1), T_{y_j}(x_2), \dots, T_{y_j}(x_M)) \right\}_{j=1}^N$$

tanítóhalmazon tanítunk,

- ekkor az NN elfogadhatóan pontos becsléseket ad az $\{u(z_k)\}_{k=1}^K$ értékek alapján az $\{u(x_i)\}_{i=1}^I$ függvényértékekre ismert u harmonikus függvény esetén.

Célunk egy olyan NN fejlesztése – beleértve a tanítófüggvények és az alappontok alkalmas megválasztását – amely a Laplace egyenlet helyett képes bizonyos speciális $f: \Omega \rightarrow \mathbb{R}$ jobboldali függvények mellett a

$$\left. \begin{aligned} \Delta u(x) &= f(x) & (x \in \Omega), \\ u|_{\partial\Omega}(x) &= g(x). \end{aligned} \right\} \quad (1.3)$$

Poisson-egyenletnek is egy hasonlóan jó tulajdonságokkal rendelkező közelítő megoldását megadni.

Vélhetően ehhez az f függvény bizonyos helyettesítési értékeit is bele kell venni valamilyen módon a tanulóhalmazba, valamint az alkalmazásokban előforduló f függvények esetén reménytelen partikuláris megoldást találni, amivel – az alapmegoldások mintájára – taníthatnánk a neurális hálót. Kérdés tehát, hogy az alapmegoldáshok helyett milyen függvényeket alkalmazunk. Néhány intuitívan adódó elképzelés az alkalmazandó T függvények tulajdonságaira

- radiális függvények, hiszen ortogonális transzformációkra a Δ operátor invariáns
- a numerikus kezelhetőség érdekében a szingularitásaik (ha vannak) az Ω tartomány külső pontjaiban lehetnek, hasonlóan a kiindulási problémához
- legyen az $\{\Delta R_\alpha\}$ halmaz lineáris burka sűrű valamilyen normában (például $\|\cdot\|_{H^1}$ normában a $H^1(\Omega)$ függvénytéren), hogy esélyünk legyen különböző, de megfelelően általános f jobboldalak esetére általánosítani a módszert.

Ilyen jó tulajdonságokkal rendelkező függvényosztályra általános választ egyelőre nem ismerünk. A [1] forrás a (r) alakú függvényeket javasolja hasonló alkalmazásokra.

A probléma megoldása során esetleg érdemes lehet a NN-ban a sűrű kötés helyett esetleg alkalmas konvolúciós kötésekkel használni több réteggel, habár a módszer leginkább egy lineáris regresszióra emlékeztet, így ez nem kecsegtet nyilvánvaló előnyökkel.

Alakítsuk át a tanulóhalmazt az alábbi módon. Legyenek adottak $\Omega \subseteq \mathbb{R}^n$ korlátos nyílt Lipschitz-tartomány, valamint

- $x_i \in \Omega$ néhány belső pontja, ahol a függvényértéket majd szeretnénk megtudni
- $y_j \in \mathbb{R}^n$ alappontok, amelyekre
- R_{y_j} radiális függvényeket helyezünk, végül
- $z_k \in \partial\Omega$ határpontok.

Legyen továbbá az NN tanítóhalmaza

$$\underbrace{((\Delta R_{y_j}(X)), (R_{y_j}(z_k))), (R_{y_j}(x_1), R_{y_j}(x_2), \dots, R_{y_j}(x_M))}_{inputok},$$

ahol $X = \{x_i\}_{i=1}^I \cup \{y_j\}_{j=1}^J$.

Ekkor a teszthalmaz az

$$\underbrace{((f(x_l)), (g(z_k))), (\dots)}_{inputok}$$

alakot ölti.

Irodalomjegyzék

- [1] Cheng, A.H.D and Hong, Y.: An overview of the method of fundamental solutions—Solvability, uniqueness, convergence, and stability, *Engineering Analysis with Boundary Elements* 120, pp. 118-152, 2020.
`idemajdkelllink`

- [2] Haffner, D. and Izsák, F.: Solving the Laplace equation by using neural networks, to appear in *Annales Univ. Sci. Budapest., Sec. Math.*
`idemajdkelllink`

- [3] Isaac Elias Lagaris, Aristidis Likas and Dimitrios I. Fotiadis: Artificial Neural Networks for Solving Ordinary and Partial Differential Equations, *IEEE Transactions on Neural Networks*, vol. 9, no. 5, 1998. szeptember
`https://faculty.sites.iastate.edu/hliu/files/inline-files/Anns_lagaris1998_0.pdf`