

Oszcillátor alapú neurális hálózatok tervezése gép tanulási módszerekkel

Rudner-Halász Tamás
A PhD Disszertáció Tézisei

Témavezető:

Dr. Csaba György PhD



Pázmány Péter Katolikus Egyetem
Információs Technológiai és Bionikai Kar
Roska Tamás Műszaki és Természettudományi Doktori Iskola

Budapest, 2025

1 Bevezetés

Az elmúlt évtizedekben a Moore-törvény nagyban érvényesült a számítógépek világában, amely kimondja, hogy az integrált áramkörökben található komponensek száma évente megduplázódik. [1], [2], [3] Annak ellenére, hogy a fizikai korlátokhoz már közel kerültünk (például source-to-drain szivárgás vagy a tény, hogy gate esetében a felhasznált fémeket tekintve korlátozottak lehetőségek), új technológiák jelentek meg, többnyire a spintronika, az alagút-csatolások és a nanohuzalozás területén, amelyek ígéretesnek bizonyulnak. [4], [5], [6]

E problémák kezelésére számos javaslat született, hogy kihasználjuk a fizikai törvények különböző adottságait a számítástechnikába, valamint olyan architektúrák megalkotására, amelyek működési elve gyökeresen eltér a hagyományos számítógépektől [7]. Az ilyen rendszerek létrehozásához a számítási problémákat teljesen más nézőpontból kell megvizsgálni. Továbbá szükséges a szokásos számítási problémák fizikai problémákká való leképezése, hogy a különböző architektúrák fizikai tulajdonságait ki lehessen használni a számítástechnikában, hasonlóan a kvantumszámítógépekhez. [8]

A legtöbb fizikai alapú számítási elmélet az energia-minimalizálás vagy a legalacsonyabb energiaszint megtalálásának valamely változatát használja; más szavakkal az optimalizálási problémák általában energia-minimalizálási feladatokra vezethetők vissza. Természetes, hogy minden rendszer a saját minimális energiaszintű konfigurációjához próbál tartani, amely megfelelő beállítások mellett a valódi megoldást (vagy azok egyikét) adja. [9]

A fizika számítási célokra történő felhasználásával a számítási eszközök egyre inkább a biológiai rendszerekhez hasonló irányba tolódnak, mivel jól látható, hogy az idegrendszer és az emberi agy az oszcillációkat használják különböző funkcióik ellátásához.

Ebben a disszertációban bemutatom az analóg neuromorfikus számítás egy új irányát, az oszcillációs neurális hálózatokat, kezdve az alapotól.

A dolgozatban bemutatom az általam létrehozott architektúrák alapjait, valamint azt, hogy a különböző területekről — nevezetesen az idegtudományból, a fizikából és a számítástechnikából — hogyan közelítettek a kutatók közösen a problémához, amely egy új, interdiszciplináris kutatási ágat hozott létre, a neuromorfikus számítógépekét.

Először áttekintem a fent említett területeket és azokat az eredményeket, amelyek a legnagyobb hatással voltak a kutatásomra, mint például a Hodgkin–Huxley-modell az idegtudományból, illetve a Kuramoto-modell, amelyet szintén biológiai oszcillátorok inspiráltak.

Ezután bemutatom az oszcillátorok két olyan áramköri implementálását, amelyekkel könnyen lehet dolgozni szimulációs környezetben.

A dolgozat és a kutatásom ettől a ponttól három szegmensre osztható. Először ismertetem, hogyan hoztam létre az ODE-rendszert a ring oszcillátor-alapú neurális hálózat szimulációjához, és hogyan tanítottam meg azokat meghatározott feladatok megoldására (I. tétel). Ezt követően bemutatom az időfüggetlen és az időfüggő feladatokat és azok megoldásait az ONN-ek segítségével.

Az időfüggetlen, statikus problémához az MNIST adatbázist használtam a kézzel írt számjegyek felismerésére bináris és többosztályos feladatként (II., III. és V. tézis).

Az időfüggő problémához — azaz az audiofelismeréshez, különösen a magánhangzó-felismeréshez — egy frekvenciaalapú számítási architektúrát mutatok be, amely a mind Kuramoto-, mind ring oszcillátoros megoldással is elkészítettem a magánhangzók felismerésére (IV. és V. tézis).

A következő paragrafusokban kiemelek két projektet, amelyek több kutatócsoport és vállalat közreműködésével zajlottak, ezzel hangsúlyozva, miért érdemes másképp gondolkodni a számítógépekről, mint eddig.

1.1. Az Intel, a BMW és az IBM közös érdeklődése egy új számítási paradigma iránt

Az elmúlt években lehetőségem nyílt több vállalattal és kutatócsoporttal együtt dolgozni különböző projekteken. A következő bekezdésekben azokat emelem ki, amelyek e disszertáció szempontjából relevánsak, és amelyek a vállalatok kívánt alkalmazásaihoz kapcsolódnak.

1.1.1. Hierarchically Interconnected Multi-layered Oscillator Networks (HIMON)

Ebben a projektben az Intel Corporation egy energiahatékony, alacsony költségű alternatívát keresett a hagyományos számítási paradigmák helyett, hogy hardverszinten oldjon meg nehéz számítási problémákat.

Motivációjuk az volt, hogy teljeskörű eszközöket találjanak NP-nehez problémákhoz, vagy gyorsítót hozzanak létre különféle, nagy számítási költségű algoritmusokhoz, például in-silico tanuláshoz.

A projektben több kutatócsoport is részt vett. A gyakorlati kutatások közé tartozott az NP-nehez problémákra való chiptervezés [10], míg az elméletibb fókuszú munkák között magasabb rendű Ising-gép megoldások is szerepeltek [11].

1.1.2. Phase Change Materials for Energy Efficient Edge Computing (PHASTRAC)

Ebben a projektben a két vállalat — IBM és BMW —, valamint a TU Eindhoven kutatócsoportja két különböző, de egymás felé konvergáló kutatási területet kapcsolt össze. A fő alkalmazási terület a BMW-től származott, akiknek céljuk gyors megoldásokat találni több, az autóban felmerülő klasszifikációs feladatra. Ennek oka főként az, hogy a modern járművekben számos szenzor található — még az utastérben is —, melyek hatalmas mennyiségű adatot termelnek, viszont a feldolgozási lehetőségek korlátozottak.

Az IBM ezzel szemben arra törekedett, hogy úgynevezett fázisváltó anyagokat felhasználva biztosítson energiahatékony megoldást az „edge computing” számítástechnikában. Ennek alapját relaxációs VO_2 oszcillátorok képezték, amelyekkel az idegsejtek működését lehetett emulálni, és amelyeket ReRAM-mal kapcsoltak össze. [12]

E két projekt alapján számomra nyilvánvaló, hogy az érdeklődés és az igény az új, nem-Boole-alapú számítási paradigmák iránt egyre nő.


2 Módszerek

2.1. ONN-ek számítási modelljei

A dolgozat elkészítése során elsősorban ring oszcillátorokat és Kuramoto-oszcillátorokat használtam a különböző feladatok megoldására.

2.1.1. A ring oszcillátor modell leírás

Az általam alkalmazott ring oszcillátor modell a 2.1. ábrán látható.



2.1. ábra. **Kétoszillátoros rendszer kapcsolási rajza mindkét csatolási móddal.** Középen egy kétoszillátoros rendszer látható, amelyet a két lehetséges módon — pozitívan és negatívan — csatoltam, számozott feszültségcsomópontokkal. Az oszcillátorokat a 7 inverter felhasználásával építettem fel. A négy sarokban a nagyított részek a rendszer lehetséges csomópont-típusait mutatják be. Ezekben a kiemelt részekben az azonos színű csomópontok azonos feszültség szinten vannak, továbbá v_{i-1} és v_{i+1} jelölik az i előtti, illetve utáni csomópontot a körkörös kialakítás miatt. A zöld nyilak az áramok konvencionális irányát jelölik. A 0-val jelölt áram az 0 A értéket szimbolizálja, mivel definíció szerint az inverterek bemeneti árama nulla. A v_- és v_+ jelölik egy másik oszcillátor feszültségcsomópontjait, amelyet adott esetben negatívan, illetve pozitívan csatoltunk az adott oszcillátorhoz. Az *Input*-ként megjelölt generátorok bármilyen külső bemeneti feszültséget biztosító források lehetnek. Megjegyzendő, hogy ezek a bemeneti generátorok áramgenerátorok is lehetnek, ebben az esetben a csatlakozó ellenállások nincsenek az áramkörben.

A szimulációhoz, tanításhoz és inferenciához használt differenciálegyenletek (ODE-k) a Kirchoff-féle áramtörvény alapján vezethetők le [13]:

- Feszültséggenerátor:

$$C \frac{dv}{dt} = \underbrace{\frac{1}{R} \mathbf{A}' (f(\mathbf{P}_\pi \mathbf{v}) - \mathbf{v})}_{\text{Belső dinamika}} + \underbrace{\frac{1}{R_c} \mathbf{C}' \mathbf{v} - \frac{1}{R_{in}} (\mathbf{B}' \odot (\mathbf{v} \ominus \mathbf{u}^T)) \mathbf{1}}_{\text{Csatolási dinamika}} \quad (2.1)$$

- Áramgenerátor:

$$C \frac{dv}{dt} = \underbrace{\frac{1}{R} \mathbf{A}' (f(\mathbf{P}_\pi \mathbf{v}) - \mathbf{v})}_{\text{Belső dinamika}} + \underbrace{\frac{1}{R_c} \mathbf{C}' \mathbf{v} - \frac{1}{R_{in}} \mathbf{B}' \mathbf{u}}_{\text{Csatolási dinamika}} \quad (2.2)$$

ahol $f(x)$ az inverterek leíró függvény:

$$f(x) = -\tanh(ax), \quad (2.3)$$

Itt $a \in \mathbb{R}^+$. Továbbá π egy permutáció, amelyre

$$\pi = \begin{pmatrix} 1 & 2 & 3 & 4 & 5 & 6 & 7 \\ 7 & 1 & 2 & 3 & 4 & 5 & 6 \end{pmatrix}, \quad (2.4)$$

és $\mathbf{P} \in \{0, 1\}^{(7n) \times (7n)}$ egy blokk-mátrix, amelynek minden 7×7 átlóbeli blokkja a π -hez tartozó permutációs mátrix. Ez rendezi a ring oszcillátor feszültségcsomópontjait, hogy kiszámíthatók legyenek a két inverter közé helyezett ellenállásokon fellépő feszültségkülönbségek.

$\mathbf{B}' \in \mathbb{R}_{\geq 0}^{(7n) \times k}$ a bemenetekhez tartozó csatolómátrix, feltételezve, hogy a bemenet $\mathbf{u} \in \mathbb{R}^k$, amely tipikusan szinuszos feszültség- vagy áramgenerátor, de lehet nem-koherens jel is. $\mathbf{C}' \in \mathbb{R}_{\geq 0}^{(7n) \times (7n)}$ a módosított csatolási mátrix, amelyet a könnyebben értelmezhető $\mathbf{C} \in \mathbb{R}^{n \times n}$ mátrixból lehet konstruálni. Az $R, C \in \mathbb{R}_{\geq 0}$ paraméterek az oszcillátorok fix jellemzői, azonban az oszcillátorok közötti tényleges ellenállás változhat — akár tanulás, akár manuális hangolás révén —, ezzel szabályozva az oszcillátorok frekvenciáját. Ezt a célt szolgálja a $\mathbf{A}' \in \mathbb{R}_{\geq 0}^{(7n) \times (7n)}$ blokk-diagonális mátrix, amely közvetlenül kapcsolódik az oszcillátorok frekvenciájához.

Megjegyzendő, hogy a hálózat tanításához a különböző feladatok megoldására a $\mathbf{A}'$, $\mathbf{B}'$ és $\mathbf{C}'$ mátrixokat használtam.

2.1.2. Kuramoto-modell

Később a Kuramoto-modellt is használtam a frekvencia-alapú számítási koncepciójának ellenőrzésére. Ez a modell teljesen matematikai jellegű, ezért tulajdonságai és viselkedése sokkal stabilabb, mint a ring oszcillátoroké, ugyanakkor jó kezdeti lépés volt annak ellenőrzésére, hogy elméletileg egyáltalán megvalósítható-e a frekvencia-alapú megközelítés.

A modellt 1975-ben Yoshiki Kuramoto vezette be, és a mai napig alapvető szerepet tölt be a nagyszámú, egymással csatolt oszcillátorok eltérő frekvenciájú populációinak szinkronizációjának matematikai modellezésében [14].

Az általam a szimulációkban használt modell a következő:

$$\frac{1}{2\pi} \frac{d\phi_i}{dt} = \underbrace{f_i}_{\text{Belső frekvencia}} + \underbrace{\sum_{j=1}^N C_{i,j} \sin(\phi_j - \phi_i)}_{\text{Csatolási dinamika}} + \underbrace{\sum_{k=1}^N B_{i,k} \sin(u_k - \phi_i)}_{\text{Külső dinamika}}$$

A modell első pillantásra eltérhet az alapmodelltől, de a különbség csupán a külső dinamika bevezetése. Itt a külső ingereket a hálózatba integrált, előre meghatározott frekvenciájú oszcillátorként ábrázoltam, amelyek egyirányú kapcsolatban állnak a nem bemeneti oszcillátorokkal, így a bemeneti oszcillátorok időben állandóak maradnak.

2.2. Tanulási módszerek

A hálózatok különböző feladatokra történő betanításához mind gradiens-alapú, mind gradiensmentes tanulási módszereket alkalmaztam.

2.2.1. Backpropagation Through Time (BPTT)

A backpropagation a neurális hálózatok betanításának de facto szabvány algoritmus [15]. A hálózat minden egyes inferenciája után a megfelelően definiált költségfüggvény gradiensét számítjuk ki a rendszer tanítható paramétereire vonatkozóan. Ezután a gradiens segítségével frissítjük a tanítható paramétereket, hogy a veszteségfüggvény minimumához konvergáljunk — lehetőleg globális, de esetenként lokális minimumhoz is.

A BPTT a backpropagation dinamikus rendszerekre (azaz ODE-alapú leírásokra) alkalmazott változata. Az ODE bármely szabványos időléptető módszerrel megoldható, akár implicit technikákkal is, diszkrét időt használva. Ez a diszkrétizált megoldás egy sokrétegű neurális hálózatként értelmezhető, ahol minden neurális réteg a rendszer időbeli pillanatképe. A BPTT algoritmus a számítás forward fázisában kiszámítja és eltárolja ezeket a rétegeket, majd a backward fázisban kiszámítja a költségfüggvény deriváltjait a tanítható paraméterekre.

A különböző ONN-ek szimulációjához és betanításához írt kód *PyTorch*-ban készült [16]. A *PyTorch* autograd funkciója lehetővé teszi a backpropagation és a BPTT egyszerű implementációját. Továbbá, bizonyos esetekben a *torchdiffq* [17] csomagot használtam differenciálható ODE-megoldók implementálásához, de néha saját megoldót alkalmaztam a feszültségértékek ellenőrzött elmentése miatt. A *torchdiffq* egy olyan Python könyvtár, amely a *PyTorch*-ra épül és különböző differenciálható ODE-megoldókat biztosít. Különösen hasznos tulajdonsága az adjungált módszer alkalmazása a visszafelé lépéshez [18], lehetővé téve a gradiens számítását állandó memóriahasználat mellett.

Fontos megjegyezni, hogy a BPTT számításigényes egy komplex dinamikus rendszer, mint az ONN-ek esetében. Egy oszcilláló architektúra időtartománybeli megoldása tipikusan több ezer időlépésből áll. Mivel a BPTT az ODE időtartománybeli megoldását sokrétegű neurális hálózattá bontja, az algoritmusnak egy több ezer rétegű hálózatot kell kezelnie, ami memóriát tekintve szűk keresztmetszethez vezethet a tanítás során.

A backpropagation sok rétegen keresztül szintén elkerülhetetlenül szenved a gradiens eltűnés

vagy robbanás problémájától [19]. Ez a backpropagation, illetve a deriválás láncszabályából ered. Ha sok rétegen megyünk visszafelé, előfordulhat, hogy a gradiens szinte nullára csökken — ami értelmes tanulási lépést nem tesz lehetővé —, vagy gyorsan a végtelenhez konvergál, ami szintén lehetetlenné teszi a tanulást. Megfigyelésem szerint az algoritmusom hasznos gradienseket produkál néhány ezer időlépésig (rétegig). A disszertációban bemutatott ONN-eket úgy építettem fel, hogy ezen időkereten belül biztonságosan konvergáljanak.

2.2.2. Nevergrad: a gradiensmentes könyvtár

A gradiensmentes optimalizálás, más néven deriváltmentes optimalizálás, olyan algoritmusokat jelöl, amelyek a célfüggvényeket gradiens-információ nélkül optimalizálják. Ezek a módszerek különösen hasznosak, ha a gradiens nem áll rendelkezésre, megbízhatatlan, vagy számításuk túl költséges, például szimulációk, black-box függvények vagy erősen nem-differenciálható függvények esetén. A gradiensmentes optimalizálás a függvény közvetlen kiértékelésére támaszkodik a jelölt megoldások iteratív javítása érdekében.


A Nevergrad egy nyílt forráskódú Python csomag, amelyet a Facebook AI Research fejlesztett gradiensmentes optimalizáláshoz [20]. Széles körű optimalizáló algoritmusokat biztosít, beleértve az evolúciós stratégiákat, CMA-ES-t, PSO-t és bandit-alapú módszereket, egységes API alatt. A Nevergrad képes kezelni folytonos, diszkrét és vegyes változós optimalizációs problémákat, így rugalmasan alkalmazható tudományos kutatásban és ipari környezetben egyaránt. Emellett jól integrálható gépi tanulási munkafolyamatokkal, és összehasonlítási eszközöket biztosít az optimalizálók teljesítményének összehasonlítására. Elérhetősége és sokoldalúsága miatt széles körben alkalmazzák black-box optimalizációs feladatoknál.

Ezt a könyvtárat a magánhangzók domináns frekvencikomponenseinek felismerésének problémájának megoldására használtam, de meg kell jegyezni, hogy ehhez a kis architektúrához BPTT-t is lehetett volna alkalmazni. Ugyanakkor a jövőbeni kísérletezés érdekében egy potenciálisan hasznos, alternatív megközelítést szerettem volna kipróbálni, mivel a BPTT korlátokba ütközik, ha az oszcillátorok száma olyan szintre nő, hogy túl sok memóriát igényelne.

3 Új tudományos eredmények


I. Tézis

Kidolgoztam egy számítási keretrendszert elektromos áramköri komponensekből felépülő oszcillátoros neurális hálózatok (ONN) tervezésére, valamint ezek időbeli visszaterjesztésen (BPTT) alapuló tanítására. Két egyszerű architektúrát hoztam létre—egyét hullámformák generálására, egyet pedig a perceptron működésének utánzására—, hogy demonstráljam: az oszcillátoros neurális hálózatok alkalmasak az ilyen eszközök megvalósítására.



3.1. ábra. **Fázisalapú számítás két ring oszcillátorral.** Az (a) ábrán az in-phase konfiguráció látható, ahol a két oszcillátort azonos feszültségcsomópontokkal kötöttem össze (pl. V_3 és V_3), lásd 2.1. A (b) ábrán anti-fázis konfiguráció látható, ahol különböző csomópontokat kötöttem össze (pl. V_3 és V_6), a fáziskülönbség a logikai inverterek késleltetése miatt jelenik meg. Az oszcillátorok ellenállásokon keresztül vannak összekapcsolva, ami a kívánt fáziskonfigurációkhoz vezeti őket. Ha a fázisok egy szürkeárnyaltos kép pixeleinek felelnek meg, a fázisdinamika előre definiált mintákhoz konvergálhat [21]. A (c) ábrán az 'A' betűre való konvergencia látható [22]


A keretrendszer *PyTorch*-ban készült, mind az ONN áramkör dinamikájának szimulációjához, mind a BPTT tanulás implementációjához. A BPTT korlátai miatt — amely a hálózat ODE-jének numerikus megoldását több száz vagy ezer rétegű mély neurális hálózattá alakítja — egyszerűsítettem az inverterek implementációját az $f(v) = -\tanh(a \cdot v)$ matematikai függvénnyel a tanulás megkönnyítése érdekében. A 3.1, 2.1, 3.2 ábrák szemléltetik a folyamatot.



3.2. ábra. Két oszcillátoros rendszer in-phase és anti-phase kapcsolatainak tanulása.


Az (a) ábrán a pozitívan kapcsolt oszcillátorok szimulációs eredménye látható, míg a (b) ábrán a negatívan kapcsolt rendszeré. Mindkét esetben a költségfüggvény magas értékről alacsony értékre csökkent. A narancssárga görbék a $\mathbf{C}$ mátrix tanulható paramétereit jelzik, nem a fizikai ellenállások tényleges értékeit. Megjegyzés: (b)-n az $R-$ paraméter nullánál kisebb értékre megy, ami matematikai szinten negatív ellenállást jelent, de a szimulációban a paramétereket nem-negatívra korlátoztam.

A keretrendszer segítségével egy 5 oszcillátoros hullámgeneráló feladatot definiáltam legkisebb négyzetes távolság veszteségfüggvénnyel, ami közel tökéletes konvergenciát eredményezett. Ez a 3.3 ábrán látható.




3.3. ábra. Hullámminta tanulása 5 összekapcsolt oszcillátorral. Az (a) ábrán az oszcillátorok kezdeti kimenete és a valós feszültség látható idő- és frekvenciatartományban. A (b) ábrán pedig a konvergencia eredményeként az algoritmus létrehozott egy hullámformát, amely idő- és frekvenciatartományban is közel van a célértékhez.

Két dimenziós, adatszétválasztó problémán is teszteltem a hálózatot 4 oszcillátorral, hogy szimuláljam egy hagyományos perceptron működését. A rendszer majdnem 100% pontosságot ért el a tanító és teszt adatokon, lásd 3.4-3.5 ábrák.



3.4. ábra. **Oszcillátor-perceptron architektúra bináris osztályozásra.** A fekete körök az oszcillátorokat, a generátorok bal oldalt, az első két oszcillátorhoz csatlakoztatva láthatók.



3.5. ábra. **Szimulált adathalmaz és tanulási eredmény.** Bal oldalon a tanító és teszt adatok színezve, jobb oldalon a tanítás során keletkezett görbék a célfüggvény értékére, valamint a tanító és tesztelő halmazokra a pontosság százalékos méréssel. A hálózat közel 100%-os pontossággal választotta szét a két halmazt.

A keretrendszer képes nem csak ring oszcillátoros, hanem Kuramoto-oszcillátoros hálózatok szimulációjára és tanítására is.


Kapcsolódó publikációk: [J1], [C1].

II. Tézis


Terveztem egy oszcillátoros neurális hálózat alapú asszociatív memóriát, amelyet időbeli visszaterjesztés (BPTT) módszerrel tanítottam, mind legközelebbi szomszéd, mind teljes összeköttetésű kapcsolási sémák alkalmazásával. Az adott adathalmazon mindkét architektúra alacsonyabb átlagos négyzetes hibát (MSE) ért el, mint a Hebb-szabállyal tanított hálózat.

A cél az volt, hogy összehasonlítsam a BPTT-vel tanított ONN-eket a Hebbian szabállyal tanítottakkal. A teljesen összekapcsolt és a legközelebbi szomszédos topológiát is implementáltam, az oszcillátorokat $N \times N$ rácsra rendezve. A 3.6 ábra ezt szemlélteti.

MNIST adathalmaznak egy részét használtam, mégpedig lecsökkentve 14×14 és 7×7 képméretekre a BPTT memóriaigénye miatt.



3.6. ábra. **ONN asszociatív memóriaként.** A bemeneti generátorok szinuszos jelet adnak a bemeneti mintának megfelelő fázissal. Ezek kapcsolódnak a hálózatban lévő oszcillátorokhoz, amelyek fázismintázata adja a megoldást. A 3–6 jelölések a bemeneti és kimeneti csomópontokat jelzik a ring oszcillátoros áramkörben. A zöld, piros és kék elemek értékei tanulhatók, a narancssárga fázisok a bemenetek. A lila vezetékek a pozitív és negatív kapcsolásokat mutatják a konvergencia érdekében. A szürkeárnyaltú kép pixeleit fázissá konvertáltam, majd a szinuszos áramgenerátorok, melyek az oszcillátorokhoz kapcsolódnak, továbbítja a bemeneti adatot a hálózat felé. A sárga nyilak az oszcillátor kimenetét és a képformálást mutatják.



3.7. ábra. **Kimeneti asszociációk összehasonlítása.** Két 5-ös blokk látható különböző bemenetekkel a különböző architektúrákhoz. Az első oszlop a bemeneti számjegyet, a következő három a hálózatok kimenetét mutatja (balról jobbra: teljesen összekapcsolt, szomszédosan kapcsolt, Hebbian). Az utolsó oszlop a célértéket mutatja. A teljesen összekapcsolt rendszer a legjobb, de a javasolt szomszéd kapcsolt topológia is felülmúlja a Hebbian-alapú hálózatot.

Az eredmények jók voltak, mivel mind a teljesen, mind a legközelebbi szomszéd kapcsolt,

BPTT-vel tanított ONN felülmúlta a Hebbian szabállyal tanított ONN-t, bizonyítva, hogy nem szükséges teljesen kapcsolt architektúrát alkalmazni. Nemcsak a kvantitatív pontosság terén teljesítettek jobban — azaz a BPTT-vel tanított hálózatok által létrehozott mintázatok MSE szempontjából közelebb álltak a valós mintázatokhoz —, hanem a paraméterszám tekintetében is, mivel a szomszédosan kapcsolt ONN jóval kevesebb paramétert használt, mint a teljesen összekapcsolt, Hebbian-alapú hálózat. Ennek fő oka, hogy a Hebbian-szabály minden mindenhez kapcsolást feltételez. Az eredmények kvantitatív összehasonlítása a 3.1 táblázatban, míg a kvalitatív összehasonlítás a 3.7 ábrán látható.

Módszer	Hebbian	Teljesen kapcsolt	Szomszédosan kapcsolt
#Param	1176	2352	312
MSE	0.068	0.020	0.047

3.1. táblázat. **Paraméterek és MSE összehasonlítása.** A teljesen kapcsolt hálózat a legjobb, de a szomszédosan kapcsolt is jobb, mint a Hebbian.


Kapcsolódó publikációk: [J1], [C1]

III. Tézis

ONN-alapú architektúrát terveztem bináris és többosztályos osztályozáshoz az MNIST adathalmazon. Létrehoztam egy kétrétegű ONN-t a 0-s és 1-es osztályok bináris osztályozására, a rejtett rétegben teljes körű (all-to-all) és legközelebbi szomszéd csatolásokkal, majd összehasonlítottam az eredményeket. Átlagosan 99%-os pontosságot sikerült elérnem, és bár a rejtett rétegben nem figyeltem meg következetes mintázatokat, ez megerősítette, hogy az algoritmus olyan struktúrákat tanult meg, amelyek az emberi szem számára nem feltétlenül felismerhetőek. Emellett több tisztán ONN-alapú architektúrát is kidolgoztam az MNIST adathalmaz többosztályos osztályozására, és teljesítményüket összevetettem egy standard neurális hálózatéval. Pontosság tekintetében ezek elmaradnak a legkorszerűbb (SOTA) megoldásoktól, azonban energiahatékonyság szempontjából az ONN-alapú megközelítések bizonyultak kedvezőbbnek.


Bár a legkorszerűbb megoldások az MNIST osztályozására 99% feletti pontosságot érnek el, ezek általában több százezer, sőt milliós paraméterszámmal rendelkeznek. A paraméterszám csökkentése érdekében érdemes kihasználni az ONN-ek dinamikáját.

Az osztályozás az egyik standard feladat a mesterséges intelligenciában. Dinamikus rendszerek, mint az Oszcilláló Neurális Hálók, nem feltétlenül a legjobb választás statikus adatok osztályozására. Ennek fő oka, hogy ilyen esetben az oszcillátorok belső dinamikáját nem használjuk ki teljes mértékben. Ennek ellenére az ONN-ekkel az osztályozás továbbra is lehetséges.




3.8. ábra. **Egyszerű két rétegű osztályozó, amely a rejtett réteg mintázatait is mutatja.** Bal oldalon látható az a felépítés, amelyet a bináris osztályozáshoz használtam. Első pillantásra feedforward-szerű elrendezésnek tűnhet, de ez csak a tisztább vizuális ábrázolás. Valójában minden oszcillátor kétirányúan kapcsolódik. Jobb oldalon látható néhány minta a 0 és 1 osztályok bináris osztályozásából, bemeneti, rejtett rétegbeli mintázat és kimeneti előrejelzés hármaskok formájában. A két piros szám a hálózat által elkövetett előrejelzési hibát jelzi. Érdeemes kiemelni, hogy bizonyos esetekben a rejtett rétegben felismerhető struktúra jelenik meg, mivel egyes fázisminták 0-nak vagy 1-nek tűnnek, de ez nem univerzális; más esetekben nincs látható, ember által felismerhető struktúra a rétegben.

A 3.8 ábrán látható, hogy egy hálózat, amely hasonlít a hagyományos neurális hálózatokra, de kétirányú információáramlást feltételez, felhasználható az MNIST bináris osztályainak megkülönböztetésére. Az ábrán azt is bemutattam, hogy a hálózat képes a 0 és 1 osztályok osztályozására. Ez nem mindig volt igaz, de néha a rejtett rétegben ember által felismerhető struktúra jelent meg. A hálózat kvantitatív teljesítménye kiváló volt, mivel a teszhalmazon 99% előrejelzési pontosságot ért el.



3.9. ábra. **Többrétegű hálózat az MNIST többosztályos osztályozására.** A felépítés hasonló az 3.8 ábrán bemutatotthoz, de a kimeneti rétegben 10 oszcillátor van egy helyett. A rejtett réteg itt kicsit kibontva látható a hálózat áttekinthetősége érdekében, de a rácsszerű struktúrája a jobb alsó sarokban látható. A pd_x értékek a kimeneti oszcillátorok és egy referencia oszcillátor közötti fáziskülönbséget jelzik. Ezek a pd_x értékek lesznek a crossentropy célfüggvény bemenetei a tényleges osztályok mellett.

A többosztályos előrejelzéshez két különböző megközelítést próbáltam ki: a hagyományos, ANN-szerű architektúrát, amely a 3.9 ábrán látható, valamint egy elosztott, bináris osztályozókon alapuló megoldást tíz versengő hálózattal. Az utóbbi logikája a 3.10 ábrán látható.



3.10. ábra. **Két a három tesztelt architektúrából az időfüggetlen MNIST osztályozáshoz.** Mindkettő egyénileg betanított, legközelebbi szomszédos kapcsolatokkal rendelkező alhálózatokból áll, amelyeket egyetlen osztály és a többi osztály megkülönböztetésére terveztem bináris crossentropy célfüggvény használatával. A felső blokkdiagram azt mutatja, hogy az előrejelzéshez az egyes hálózatok kimeneti valószínűségeinek maximumát vettük. Az alsó, összetettebb blokkdiagram azt mutatja, hogy az egyéni osztályozók kimeneti valószínűségeit egy kis, hagyományos FFNN bemeneteként használtuk, és úgy tanítottuk, mintha 10 osztályos osztályozási problémát oldanánk meg crossentropy segítségével.

Sajnos a tisztán ONN-alapú hálózatok teljesítménye nem érte el a kívánt szintet, ezért az ONN és ANN kombinációját alkalmaztam. Az ebben a tézispontban bemutatott hálózatok összehasonlítása a 3.2 táblázatban látható.


	ONN	WTIA	Augmented	MLP
#Param	40180	16000	16325	16363
Teljesítmény (%)	72.3 (70–75)	66.7 (65–70)	95.1 (93–97)	94.4 (93–95)

3.2. táblázat. **Kvantitatív összehasonlítás többosztályos osztályozók között.** A Teljesítmény (%)‘mező ‘átlag (tartomány)’formátumban van. Az FFNN-nel kiegészített (Augmented) hálózat egy két rétegű többrétegű perceptron hálózatot használ végső döntési függvényként. Megjegyzendő, hogy a tisztán ONN verzió paraméterszáma a 14×14 méretű rejtett rétegre vonatkozik, mivel a 7×7 réteg teljesítménye rendkívül gyenge volt.

A témához kapcsolódó publikációk: [J1], [C2], [C3]

IV. Tézis


Létrehoztam egy frekvenciaalapú oszcillátoros neurális hálózatot a Kuramoto-modell és a ring-oszcillátor-alapú modellek felhasználásával. A hálózatok paramétereit manuálisan, illetve egy gradiensmentes optimalizációs módszer segítségével hangoltam be. A kidolgozott hálózat mindkét modell és paraméter-finomhangolási séma alkalmazásával képes volt a kitűzött feladatot 100%-os pontossággal megoldani.



3.11. ábra. **Oszcillátorok frekvenciaszinkronizációja a bemeneti szinusz jel adott frekvenciáira.** Egyetlen bemeneti szinusz feszültséggenerátor frekvenciavizsgálata látható, amely 24 nem összekapcsolt oszcillátorra van kötve. A négy különböző oszcillátorcsoport vagy szinkronizálódik a bemeneti jellel, vagy nem, a bemeneti frekvenciától függően. Minden csoportban az oszcillátorok egyesével szinkronizálódnak a bemeneti jel frekvenciájára, amíg mind szinkronban nem lesz, majd együtt futnak egy adott frekvenciatartományban, majd újra egyesével eltávolodnak a csoport többi tagjától frekvenciájukat tekintve.

A szakirodalomban az oszcillátorokat leginkább fázisalapú számításokra használják. Ugyanakkor lehetséges frekvenciaalapú architektúrákat is építeni, kihasználva az oszcillátorok frekvenciaszinkronizációs tulajdonságát, amint azt a 3.11 ábra is mutatja.

Ezen elv alapján lehetséges egy, a 3.12 ábrán látható architektúra tervezése, amely korlátozott számú paraméterrel rendelkezik, ahogy azt a 3.3 táblázat is mutatja, és amely két magánhangzó megkülönböztetésére használható a két domináns frekvenciákomponenseik alapján.



3.12. ábra. **A javasolt architektúra.** A bemeneti jeleket szinuszos feszültséggenerátorok képviselik. Ezek frekvenciáját a bemeneti magánhangzó első és második legdominánsabb frekvenciaösszetevője határozza meg. Ezeket egyetlen réteg, egymással nem összekapcsolt oszcillátoraihoz csatlakoztatjuk, amelyek 4 külön csoportba vannak rendezve, hogy kiemeljük a csoportok kollektív felelősségét a bemeneti jel bizonyos frekvenciájának detektálásában. A csoportok frekvenciaszinkronban vannak, ha a bemeneti szinusz frekvenciája a csoport által lefedett tartományba esik. Ezeket a csoportokat egy pár kimeneti oszcillátorhoz csatlakoztattam, amelyek ugyanazt a frekvenciatartományt fedik le. Ha bármelyik csoportban a 6 oszcillátor frekvenciaszinkronban van, a kimeneti réteg oszcillátorai is szinkronizálódnak, amik az adott csoporthoz vannak kötve. Így a bemeneti szinuszok bizonyos frekvenciáit különböző csoportok jelzik.

3.3. táblázat. **Javasolt többrétegű oszcilláló hálózat neuron-, kapcsolás- és paraméterszámai.** A hálózat kicsi, mindössze 72 kapcsolással — beleértve a bemenetek és oszcillátorok közötti kapcsolatokat. Megjegyzendő, hogy a tényleges paraméterszám az oszcillátorok és kapcsolások összegéből adódik: az oszcillátorok a frekvencia beállításáért felelősek, a kapcsolások pedig az összekapcsolt oszcillátorok közötti kapcsolaterősséget határozzák meg.

	<i>Bemenet</i>	<i>Réteg #1</i>	<i>Réteg #2</i>	<i>Összesen</i>
<i>Neuronok száma</i>	2	24	8	34
<i>Frekvencia paraméterek</i>	0	24	8	32
<i>Kapcsolások a következő réteghez</i>	24	48	0	72
<i>Összes paraméter</i>	24	72	8	104

A hálózat segítségével sikerült két angol magánhangzót, az ‘ah’-t és az ‘iy’-t 100% pontossággal megkülönböztetni, ami tovább bizonyítja, hogy frekvenciaalapú architektúra működőképes.

Ez egyúttal jó párhuzamot mutat a korábban bemutatott fázisalapú perceptronnal, mivel a hálózat bizonyos szempontból ekvivalens azzal az architektúrával.

A paraméterek hangolása, amely a 3.4 táblázatban látható, manuális beállítással és gradiensmentes optimalizációs módszerrel történt, amelyet az oszcilláló neurális hálózat optimális paramétereinek megtalálására használtam. Ezt a módszert azért alkalmaztam, hogy kipróbáljam a hálózat képességeit, mivel a BPTT-módszer nagy kihívást jelenthet, ha az architektúra olyan méretűvé válik, hogy a gradiensalapú módszer hatalmas memóriaigényt szücségettetne.

3.4. táblázat. **Ring oszcillátor-hálózat fizikai paraméterei a domináns frekvenciakomponensek felismeréséhez.** Minden paraméter kísérletezés útján lett beállítva, és a szimulációkhoz használtuk.

Paraméter	Fizikai érték
C	$1.0 \cdot 10^{-13} \text{ F}$
R	$2.0 - 2.7 \cdot 10^3 \Omega$
R_{in}	$1.0 \cdot 10^4 \Omega$
R_c	$1.2 - 2.2 \cdot 10^6 \Omega$
V_{in}	1 V

A témához kapcsolódó publikációk: [J2], [C4].

V. Tézis csoport

Két feladaton – az MNIST adathalmazon és a magánhangzó-felismerésen – keresztül, mind fázis-, mind frekvenciaalapú számításokkal sikeresen demonstráltam, hogy az ONN-ek standard


neurális hálózatokkal kombinálva hatékonyan alkalmazhatók előfeldolgozó réteggként. Ez rávilágít az oszcillátoros neurális hálózatok jelentőségére az energiahatékonyság terén, valamint arra a képességükre, hogy alkalmasak nagyméretű problémák kezelésére is.

Sajnos a tisztán oszcillátoralapú hálózatok nem értek el elegendő teljesítményt az MNIST klasszifikációs feladaton. Az ONN és a hagyományos ANN kombinációja azonban lehetővé teszi a hagyományos, hasonló méretű neurális hálózatokkal azonos teljesítmény elérését.

V.1 Tézis: Az MNIST osztályozási feladathoz tervezett legjobb ONN-hálózatot egy standard ANN-nel kombináltam, így egy olyan hibrid ONN-ANN architektúrát hoztam létre, amely egy 10-osztályos osztályozási feladaton átlagosan 95,1%-os pontosságot ért el. Összehasonlításképpen: egy azonos paraméterszámú, hagyományos FFNN-hálózat ugyanazon a problémán átlagosan 94,4%-os pontosságot mutatott.

Mivel a tisztán oszcillátoralapú hálózat nem tudott magas pontosságot elérni az MNIST adathalmazon, még elosztott, versengő hálózatok és a „winner takes all” algoritmus alkalmazása esetén sem, ezért a Konvolúciós Neurális Hálózatokból (CNN) átvett megközelítést alkalmaztam, azaz néhány réteg után egy teljesen összekapcsolt, több rétegű perceptron hálózat végzi az osztályozást.

Az általam használt architektúra a 3.13 ábrán látható és az összes, MNIST klasszifikációra tervezett hálózattal való összehasonlítása pedig a 3.2 táblázatban található meg.




3.13. ábra. ONN rétegeket előfeldolgozóként használó hálózat és hagyományos neurális hálózat együttműködése. A könnyen tanítható kimeneti réteg jelentősen javítja az osztályozás pontosságát, miközben a hálózat alacsony komplexitása megmarad a legmodernebb megoldásokhoz képest. A munka nagy részét továbbra is az ONN-ek végzik előfeldolgozóként, nem pedig a végső kis neurális hálózat.

Ezzel a kombinált hálózattal legfeljebb 96,7% osztályozási pontosságot értem el. Összehasonlításképp, egy hasonló méretű, hagyományos neurális hálózat legfeljebb 95% pontosságot ért el, ami nagyon jó eredmény, figyelembe véve, hogy a hálózatot csak néhány epókon képezték — a számítási kapacitás végeessége miatt — és a paraméterszáma is nagyon alacsony volt.


A témához kapcsolódó publikációk: [J1], [C2], [C3]

V.2 Tézis: *Létrehoztam egy vegyes hálózatot, amelyben az ONN-ek előfeldolgozóként, egy többrétegű perceptron (MLP) pedig kimeneti réteggként funkcionál a kimondott magánhangzók eredeti, időfüggő hullámformáiból történő felismeréséhez. A tesztelt adathalmazon az algoritmus 95%-os pontosságot ért el. A megoldás fő előnye, hogy a hálózat alacsony komplexitású és számítási szempontból kifizogasztású, mivel mind az ONN-réteg, mind az ONN kimeneti jelét statikus adatokká alakító transzformációs réteg kizárólag egyszerű elektromos komponensekből épült fel.*



3.14. ábra. **Vegyes architektúra időtartománybeli bináris magánhangzó-felismeréshez.** Az architektúra első része a magánhangzók frekvenciajellemzőit nyeri ki a szomszédos oszcillátorok frekvenciaszinkronizációs erősségének mérésével. A második rész ezt a statikus adatot használja bemenetként a tényleges bináris felismeréshez egy egyszerű, több rétegű perceptron architektúrában.


A kombinált ONN- és ANN-hálózat sikerére építve létrehoztam egy hálózatot magánhangzók osztályozására. Ehhez a feladathoz a magánhangzók időfüggő hullámformáit használtam a domináns frekvenciakomponensek helyett. Az első, oszcillátoralapú réteg felelős a frekvenciainformációk kinyeréséért a magánhangzók, létrehozva egy szűrőhöz hasonló réteget.



3.15. ábra. **Két szomszédos szinkronizáló oszcillátor kimeneti jeleinek átalakítása.**

A két, szomszédos oszcillátor jelen végzett átalakítások a kis áramkörön keresztül láthatók (a)–(d) ábrákon: (a) a szinkronizáló oszcillátorok kimeneti feszültségei a szinkronizációs időtartomány közelében; a szinkronizációs régióban az oszcillátorok frekvenciája nem változik egymáshoz képest, de előtte és utána az 1. oszcillátor folyamatosan mozog a 0. oszcillátor felett mint a magasabb frekvenciájú oszcillátor; (b) a kimeneti jelek digitalizálása után két négyszögjel látható; (c) a szinkronizáló jelek XOR műveletének viselkedése hasonló az (a) ábrához, a szinkronizációs régióban az XOR állandó kitöltésű jelet ad, azon kívül a kitöltés hossza folyamatosan változik; (d) az XOR jel egészére alkalmazott átlagoló szűrő után a szinkronizációs régió egyértelműen látható, és, ha megszámloljuk az x -tengelyen való metszeteit a görbének, akkor alacsonyabb értéket ad, mintha a szinkronizáció nem lett volna jelen. A jel értékét a $[0, 1]$ tartományra transzformáltam és kivontam 1-ből, hogy a relatív jel-erősséget kapjuk, amit szinkronizációs erősségnek neveztem el.

Ez a frekvencia-reprezentáció alapvetően a jel gyors Fourier-transzformáltjának (FFT) lecsökkentett mintavételezése, és egyetlen magánhangzóhoz tartozó jellemzők kinyerését csupán egyszerű elektromos áramköri elemek felhasználásával végeztem, ahogy az a 3.14 ábrán is látható. A jellemzők kinyerésének folyamata a 3.15, az eredménye pedig a 3.16 ábrán látható.



3.16. ábra. **Példa a jellemzők kinyerésére az oszcilláló réteggel.** A kinyert szinkronizációs erősséget reprezentáló vektor elemei magasak, ha a két oszcillátor között szinkronizáció van, alacsonyak, ha nincs, ahogy terveztem. A magánhangzó frekvenciaspektruma bal oldalon van, 90 fokkal elforgatva az átláthatóság miatt. A színes görbék az egyes oszcillátorok pillanatnyi frekvenciáit jelölik.

A ‘ah’ és ‘iy’ magánhangzókat teszteltem, és körülbelül 95% pontossággal sikeres osztályozást értem el. Ez jó eredmény, mivel a szakirodalom többsége az időfüggő hangjelekre egy dimenziós sorozatként tekint, vagy Mel-spektrogrammá alakítja, és képfelismerő hálózatokat használ.

Az általam bemutatott megközelítés új módot kínál az ilyen klasszifikációs feladatok megoldásának komplexitásának csökkentésére, és utat nyit olyan architektúrák számára, amelyek közvetlenül képesek adatokat fogadni az érzékelőktől.

A témához kapcsolódó publikációk: [J2], [C4]

Köszönetnyilvánítás

Először is szeretném kifejezni legmélyebb hálámat témavezetőmnek, Csaba György professzornak, az értékes útmutatásáért, bátorításáért és rendíthetetlen támogatásáért, amelyet az elmúlt több, mint 8 év során nyújtott. A meglátásai és szakértelme nemcsak a munkámat formálták, hanem jelentős szerepet játszottak abban amilyen kutatóvá váltam.

Hálás vagyok Wolfgang Porod professzornak a Notre Dame Egyetemről, amiért lehetőséget kaptam vele együtt dolgozni a kutatás egyes részein. Az ő széleskörű tudása és az együttműködés során megosztott tapasztalatai inspirálóak és gazdagítóak voltak.

Őszinte köszönet illeti az Intel csapatát, különösen Narayan Srinivasa-t, Dmitri Nikonov-ot és Amir Khosrowshahi-t, rendszeres útmutatásukért és diszkusszióikért. Segítettek formálni a javasolt megoldás gyakorlati alkalmazhatóságáról alkotott elképzelésemet, és értékes perspektívát nyújtottak a jelenlegi ipari érdeeltségekről.

Szeretném megköszönni a PHASTRAC konzorciumnak is a kétheti találkozókat és az ott kapott konstruktív visszajelzéseket. Különösen hálás vagyok az Aida Todri-Sanial professzor által vezetett TU Eindhoven remek csapatának az időfüggő jelfeldolgozás áramkörökkel történő szoros együttműködésükért, valamint az IBM és a BMW csapatoknak az alkalmazásukért, hozzászólásaikért és észrevételeikért.

Nagyon hálás vagyok az egyetemen tapasztalt közösségi élményért, amelyet a többi doktori hallgató között élhettem át. Különösen szeretném megköszönni Balogh Gábor Dánielnek, Sulyok András Attilának, Siklósi Bálintnak és Vághy Mihály Andrásnak, akik mindig készek voltak beszélgetni — legyen szó kutatásról vagy az azon túli életéről.

Külön köszönet illeti a Pázmány Péter Katolikus Egyetem Információs Technológiai és Bionikai Karát, hogy részt vehettem a doktori programjukban. Különösen hálás vagyok Szederkényi Gábor professzornak és Csurgay Árpád professzornak az iránymutatásukért és a doktoranduszi tanulmányaim során nyújtott rendszeres visszajelzéseikért. Hasonlóképpen mély hálával tartozom minden kollégának a Pázmány Péter Katolikus Egyetemen, akiknek támogatása és munkájuk lehetővé tette ezen dolgozat elkészültét. Külön szeretném megköszönni Dr. Vida Tivadarné (Katinka néni) kedvességét és folyamatos segítőkészségét. Mosolya és bátorítása erőt adott még a legnehezebb pillanatokban is.

Mély hálával tartozom édesanyámnak, akinek szeretete, bátorítása és rendíthetetlen támogatása formált azzá a személlyé, aki ma vagyok. Végül, és legfőképpen, szeretném kifejezni legmélyebb köszönetemet Rudner-Halász Lenke felé, aki az évek során mellettem állt, szeretetével, türelmével és bátorításával. Jelenléte újra és újra emlékeztetett arra, hogy nélküle nem tudtam volna elérni ezt a célt.

Publikációk

Folyóirat publikációk

- [J1] T. Rudner, W. Porod és G. Csaba, „Design of oscillatory neural networks by machine learning”, *Frontiers in Neuroscience*, 18. évf., 1307525. old., 2024. márc. DOI: 10.3389/fnins.2024.1307525 (hiv. old. 10, 12, 16, 20).
- [J2] T. Rudner-Halász, W. Porod és G. Csaba, „Oscillator-Based Processing Unit for Formant Recognition”, *Information*, 16. évf., 7. sz., 2025, ISSN: 2078-2489. DOI: 10.3390/info16070611. cím: <https://www.mdpi.com/2078-2489/16/7/611> (hiv. old. 18, 22).

Konferenciárészvételek, poszterek

- [C1] T. Rudner, G. Csaba és W. Porod, „Design of Oscillatory Neural Networks by Machine Learning Algorithms”, *International Workshop on Computational Nanotechnology*, Conference presentation, 2023 (hiv. old. 10, 12).
- [C2] T. Rudner, W. Porod és G. Csaba, *Design of Oscillatory Neural Networks by Machine Learning Techniques*, Poster presented at the Workshop “Frontiers of Neuromorphic Computing”, 2023 (hiv. old. 16, 20).
- [C3] T. Rudner, W. Porod és G. Csaba, *Design of Oscillatory Neural Networks by Machine Learning*, Poster presented at the European Conference on Machine Learning and Principles and Practice of Knowledge Discovery in Databases, 2023 (hiv. old. 16, 20).
- [C4] T. Rudner, W. Porod és G. Csaba, *Training Oscillator Networks for Neuromorphic Computing*, Poster presented at the International Conference on Neuromorphic Computing and Engineering, 2024 (hiv. old. 18, 22).

Irodalomjegyzék

- [1] G. Moore, „Cramming More Components Onto Integrated Circuits”, *Proceedings of the IEEE*, 86. évf., 1. sz., 82–85. old., 1998. DOI: 10.1109/jproc.1998.658762 (hiv. old. 2).
- [2] G. E. Moore, „Progress in digital integrated electronics [Technical literature, Copyright 1975 IEEE. Reprinted, with permission. Technical Digest. International Electron Devices Meeting, IEEE, 1975, pp. 11-13.]”, *IEEE Solid-State Circuits Society Newsletter*, 11. évf., 3. sz., 36–37. old., 2006. szept., ISSN: 1098-4232. DOI: 10.1109/N-SSC.2006.4804410 (hiv. old. 2).
- [3] C. A. Mack, „Fifty Years of Moore’s Law”, *IEEE Transactions on Semiconductor Manufacturing*, 24. évf., 2. sz., 202–207. old., 2011. máj., ISSN: 1558-2345. DOI: 10.1109/TSM.2010.2096437 (hiv. old. 2).
- [4] D. E. Nikonov és I. A. Young, „Overview of Beyond-CMOS Devices and a Uniform Methodology for Their Benchmarking”, *Proceedings of the IEEE*, 101. évf., 12. sz., 2498–2533. old., 2013. dec., ISSN: 1558-2256. DOI: 10.1109/JPROC.2013.2252317 (hiv. old. 2).
- [5] S. Manipatruni, D. E. Nikonov és I. A. Young, „Material Targets for Scaling All Spin Logic”, *ArXiv*, abs/1212.3362 évf., 2012 (hiv. old. 2).
- [6] B. Behin-Aein, D. Datta, S. Salahuddin és S. Datta, „Proposal for an all-spin logic device with built-in memory”, *Nature nanotechnology*, 5. évf., 266–70. old., 2010. febr. DOI: 10.1038/nnano.2010.31 (hiv. old. 2).
- [7] K. Zuse, „The computing universe”, *Int. J. Theor. Phys*, 21. évf., 589–600. old., 6-7 1982. DOI: 10.1007/BF02650187 (hiv. old. 2).
- [8] P. Benioff, „The computer as a physical system: A microscopic quantum mechanical Hamiltonian model of computers as represented by Turing machines”, *Journal of Statistical Physics*, 22. évf., 5. sz., 563–591. old., 1980. máj., ISSN: 1572-9613. DOI: 10.1007/BF01011339. cím: <https://doi.org/10.1007/BF01011339> (hiv. old. 2).
- [9] C. Kim, „Coupled Oscillator based Computing: Using Nature to Solve Difficult Problems”, *IBM Unconventional Computing Paradigm Workshop*, 2021 (hiv. old. 2).
- [10] H. Cilasun és tsai., „3SAT on an all-to-all-connected CMOS Ising solver chip”, *Scientific Reports*, 14. évf., 1. sz., 10757. old., 2024. DOI: 10.1038/s41598-024-60316-y. cím: <https://doi.org/10.1038/s41598-024-60316-y> (hiv. old. 3).
- [11] C. Bybee, D. Kleyko, D. E. Nikonov, A. Khosrowshahi, B. A. Olshausen és F. T. Sommer, „Efficient optimization with higher-order Ising machines”, *Nature Communications*, 14. évf., 1. sz., 6033. old., 2023. DOI: 10.1038/s41467-023-41214-9. cím: <https://doi.org/10.1038/s41467-023-41214-9> (hiv. old. 3).

- [12] V. Clerico és tsai., „Edge Training and Inference with Analog ReRAM Technology for Hand Gesture Recognition”, *arXiv preprint arXiv:2502.18152*, 2025. DOI: 10.48550/arXiv.2502.18152. cím: <https://doi.org/10.48550/arXiv.2502.18152> (hiv. old. 3).
- [13] X. Lai és J. Roychowdhury, „Analytical equations for predicting injection locking in LC and ring oscillators”, *Proceedings of the IEEE 2005 Custom Integrated Circuits Conference, 2005.*, San Jose, CA, USA: IEEE, 2005, 454–457. old., ISBN: 9780780390232. DOI: 10.1109/CICC.2005.1568706. elérés dátuma 2023. okt. 2. cím: <http://ieeexplore.ieee.org/document/1568706/> (hiv. old. 4).
- [14] Y. Kuramoto, „Self-entrainment of a population of coupled non-linear oscillators”, *International Journal of Engineering Science*, 16. évf., 11. sz., 1187–1206. old., 1975 (hiv. old. 5).
- [15] Y. LeCun, Y. Bengio és G. Hinton, „Deep learning”, *Nature*, 521. évf., 7553. sz., 436–444. old., 2015. máj., ISSN: 0028-0836, 1476-4687. DOI: 10.1038/nature14539. elérés dátuma 2023. okt. 2. cím: <https://www.nature.com/articles/nature14539> (hiv. old. 6).
- [16] A. Paszke és tsai., *Automatic Differentiation in PyTorch*, Long Beach, CA, USA, 2017. cím: <https://openreview.net/forum?id=BJJsrmfCZ> (hiv. old. 6).
- [17] R. T. Q. Chen, *torchdiffeq*, 2018. cím: <https://github.com/rtqichen/torchdiffeq> (hiv. old. 6).
- [18] R. T. Q. Chen, Y. Rubanova, J. Bettencourt és D. Duvenaud, „Neural Ordinary Differential Equations”, *Advances in Neural Information Processing Systems*, 2018 (hiv. old. 6).
- [19] T. P. Lillicrap és A. Santoro, „Backpropagation through time and the brain”, *Current opinion in neurobiology*, 55. évf., 82–89. old., 2019 (hiv. old. 7).
- [20] C. Rapin és O. Teytaud, *Nevergrad - A gradient-free optimization platform*, GitHub repository, 2018. cím: <https://github.com/facebookresearch/nevergrad> (hiv. old. 7).
- [21] G. Csaba és W. Porod, „Noise Immunity of Oscillatory Computing Devices”, *IEEE Journal on Exploratory Solid-State Computational Devices and Circuits*, 6. évf., 2. sz., 164–169. old., 2020. dec., ISSN: 2329-9231. DOI: 10.1109/JXCDC.2020.3046558. elérés dátuma 2023. okt. 2. cím: <https://ieeexplore.ieee.org/document/9302732/> (hiv. old. 8).
- [22] G. Csaba, T. Ytterdal és W. Porod, „Neural network based on parametrically-pumped oscillators”, *2016 IEEE International Conference on Electronics, Circuits and Systems (ICECS)*, Monte Carlo, Monaco: IEEE, 2016. dec., 45–48. old., ISBN: 9781509061136. DOI: 10.1109/ICECS.2016.7841128. elérés dátuma 2023. okt. 2. cím: <http://ieeexplore.ieee.org/document/7841128/> (hiv. old. 8).