

## Contribuții la determinarea arhitecturii rețelelor neuronale

### Teză de doctorat – Rezumat

pentru obținerea titlului științific de doctor la

Universitatea Politehnică Timișoara

în domeniul de doctorat Calculatoare și tehnologia informației

autor **Mohamed Laffif Tej**

conducător științific Prof.univ.dr.ing. Ștefan Holban

### Rezumat

Această teză își propune să creeze o metodă generală pentru determinarea arhitecturii optime a rețelei neuronale folosind tehnici din domeniul extragerii de date (engl. data mining). Extragerea de date este utilizată pentru explorarea unor date de învățare a unei rețele neuronale pentru identificarea tiparelor și stabilirea relațiilor ce pot duce la predicții rezonabile, în legătură cu arhitectura optimă a unei rețele neuronale multistrat.

Nu există metode directe suficient de dezvoltate pentru determinarea apriori a arhitecturii optime a rețelelor neuronale. Majoritatea metodelor utilizate în prezent sunt foarte limitate și mari consumatoare de timp. Chiar tehnicile consacrate rezolvă doar câteva aplicații, în condiții particulare. În prezent, suntem departe de stabilirea unei teorii viabile pentru determinarea arhitecturii unei rețele neuronale, în funcție de complexitatea problemei care trebuie rezolvată. Acest studiu își propune să determine arhitectura unei rețele neuronale și numărul de straturi ascunse, precum și numărul de neuroni de pe aceste straturi. Pentru asta, voi utiliza tehnici din domeniul extragerii de date, pentru analiza informațiilor care urmează să fie prelucrate de o rețea neuronală. Intenționez să analizez datele care urmează să fie prelucrate de o rețea neuronală multistrat prin intermediul unor tehnici de grupare, în contextul unui mod de lucru nesupravegheat și să corelez numărul de grupe astfel obținut cu numărul optim de straturi ascunse pentru o rețea neuronală multistrat. Pentru stabilirea numărului de neuroni de pe fiecare strat ascuns voi folosi rezultatele obținute prin gruparea formularelor din baza de date analizată în raport cu o distanță de referință.

Această teză prezintă o nouă metodă generală pentru determinarea arhitecturii optime a rețelei neuronale, folosind metoda regresiei liniare. Pornind de la gruparea mulțimii de date utilizate pentru învățarea unei rețele neuronale, putem defini modele de regresie liniară multiplă pentru determinarea arhitecturii unei rețele neuronale. Spre deosebire de alte metode, aceasta este mai flexibilă, relativ la diferite categorii de mulțimi de date. Metoda propusă se adaptează complexității mulțimilor de date de învățare pentru a oferi cele mai bune rezultate, indiferent de dimensiunea și tipul mulțimii de date.

Metoda propusă reduce timpul alocat pentru proiectarea rețelei. Această metodă poate face proiectarea mai simplă, mai facilă și accesibilă chiar unui designer nespecializat. Esențial a fost să dezvolt o soluție rapidă (în ceea ce privește învățarea iterațiilor) menținând și o eficiență acceptabilă.

**Keywords (cuvinte-cheie):** Inteligență artificială, învățare automată, arhitectura rețelelor neuronale, data mining, metode de grupare, rețea neuronală multistrat, pattern recognition, analiza regresiei.

## 1. Introducere

Preocupările cercetătorilor din domeniu s-au concentrat pe teoria conform căreia computerele pot învăța să îndeplinească sarcini specifice, fără a fi programate [1], iar cercetătorii din domeniul inteligenței artificiale [2] au dorit să vadă dacă calculatoarele pot învăța din datele furnizate. Învățarea automată oferă computerului capacitatea de a învăța fără a fi explicit programat [3].

Rețelele neuronale artificiale au inspirație biologică [4]. O paradigmă din programare, de inspirație biologică, permite unui computer să învețe din datele experimentale. Cu mai mult de două decenii în urmă, rețelele neuronale erau percepute de public drept următoarea generație de mașini de calcul, cea care, în sfârșit, ar permite computerelor să gândească singure.

Realizarea arhitecturi optime pentru o rețea neuronală este necesară datorită aplicațiilor acestora în imagistica medicală (localizarea tumorilor și altor patologii, măsurarea volumului țesuturilor, chirurgie asistată de calculator, diagnoză, planificarea tratamentului), localizarea obiectelor în imagini din satelit, recunoaștere facială, recunoașterea irisului, recunoașterea amprentelor, sisteme de control ale traficului și multe altele [5]. Aceste aplicații recomandă domeniul ca pe unul de actualitate, întrucât cercetătorii alocă multe resurse pentru obținerea de rezultate satisfăcătoare sau chiar apropiate de cele ideale.

### 1.1. Expunerea problemei

În această teză vom prezenta o critică științifică a arhitecturii rețelei neuronale în care nu există metode analitice generale pentru determinarea numărului optim de straturi ascunse [6] și a numărului de neuroni din aceste straturi [7] pentru cazul unei rețele neuronale multistrat [8]. În literatura de specialitate sunt descrise o serie de arhitecturi de rețele neuronale, dar acestea rezolvă cu succes doar un număr redus de aplicații, în condiții particulare. Proiectarea structurii rețelei neuronale este un domeniu extrem de fertil în cercetare și care nu are, încă, multe principii teoretice clare de urmat.

În experimentele făcute de diferiți cercetători pe probleme specifice, cum ar fi arhitectura optimă, s-au obținut rezultate doar în cazuri particulare. Alegerea numărului de straturi ascunse și a numărului neuronilor este o problemă complexă și un pas esențial în proiectarea unei rețele neuronale pentru care nu există teorii universale viabile. În prezent, suntem departe de a avea o teorie viabilă pentru determinarea dimensiunii unei rețele neuronale, în funcție de complexitatea problemei de rezolvat [9].

### 1.2. Metoda de cercetare

În acest sens, autorul intenționează să folosească tehnici de tip extragere de date pentru analizarea datelor utilizate pentru învățarea unei rețele neuronale. Această metodă va funcționa nesupravegheat pentru analizarea datelor de învățare prin tehnici de grupare și pentru a corela numărul de grupuri obținute cu numărul optim de straturi ascunse, în cazul unei rețele neuronale multistrat. Pentru a determina numărul de neuroni de pe fiecare strat ascuns vom utiliza rezultatele grupând formulele de învățare din baza de date analizată pe baza unei distanțe de referință.

Pentru a calcula numărul de neuroni din straturile ascunse, se va dezvolta un model de regresie liniară multiplă, care utilizează parametri obținuți din gruparea mulțimii de date de învățare. Utilizarea acestei metode permite proiectarea unei rețele neuronale optime nesupravegheate reducând și timpul de generare al acesteia.

### 1.3. Cuprinsul tezei

Următoarea parte a prezentei teze este structurată astfel:

- **Capitolul 2** prezintă o analiză a rețelelor neuronale și explică efectul arhitecturii rețelei neuronale asupra capacității de învățare a acesteia. În plus, conține o prezentare a metodelor utilizate în prezent pentru determinarea arhitecturii rețelei neuronale.
- **Capitolul 3** descrie metodele utilizate pentru determinarea unei arhitecturi neuronale optime folosind tehnicile de grupare, prin prezentarea etapelor pe care trebuie să le parcurgem pentru determinarea arhitecturii rețelei neuronale. În plus, se mai prezintă o discuție despre tehnicile de grupare utilizate și un studiu comparativ al măsurării distanței de grupare utilizate pentru a determina arhitectura rețelei neuronale.
- **Capitolul 4** descrie o altă tehnică folosită pentru determinarea unei arhitecturi neuronale optime, prin utilizarea unor metode de regresie. Rezultatele obținute în urma grupării datelor de învățare sunt demonstrate a fi consistente pentru dezvoltarea unui model de regresie liniară multiplă, în conformitate cu scopul de determinare a numărului de straturi ascunse și a celui de neuroni pe fiecare strat, pentru o rețea neuronală multistrat. În acest capitol va fi prezentată o discuție despre factorii selectați și influența fiecăruia dintre aceștia asupra numărului de straturi ascunse și a celui de neuroni ascunși.
- **Capitolul 5** descrie importanța analizei datelor de învățare pentru îmbunătățirea capacităților de generalizare a arhitecturii rețelei neuronale. Se arată că performanța de generalizare a rețelelor neuronale este afectată de structura rețelei.
- **Capitolul 6** descrie o comparație a metodei propuse cu metodele cele mai utilizate în prezent. Acest capitol arată modalitatea prin care metoda propusă funcționează bine pentru diferitele tipuri de mulțimi de date și cum aceasta este adaptată complexității datelor de învățare, pentru a oferi cele mai bune rezultate, indiferent de dimensiunea și tipul mulțimii de date, spre deosebire de alte metode.
- **Capitolul 7** prezintă un rezumat al rezultatelor obținute și încheie această teză.

## 2. Structura rețelelor neuronale

Cea mai importantă problemă teoretică rezolvată în această teză este dată de corelația dintre structura rețelei neuronale și capacitatea de învățare a acesteia. Pentru a rezolva o problemă complexă folosind rețeaua neuronală este nevoie de o structură complexă a rețelei reprezentată de numărul de straturi ascunse și de cel de neuroni ascunși. Dimensiunea rețelei afectează capacitatea de învățare a acesteia, ceea ce face ca adăugarea mai multor straturi ascunse și neuroni în aceste straturi să fie esențială, atunci când crește complexitatea problemei care trebuie rezolvată.

Se poate dovedi teoretic că o rețea neuronală care are ca avantaj utilizarea mai multor straturi ascunse îmbunătățește capacitatea predictivă a rețelei. Întrebarea este de câte straturi ascunse este nevoie, în funcție de nivelul de complexitate al problemei care trebuie rezolvate de rețeaua neuronală, fără a depăși numărul necesar de straturi ascunse (pentru a evita scăderea preciziei în mulțimea de date de test). Creșterea numărului de straturi ascunse mai mult decât este necesar va face ca rețeaua să fie supra-pregătită pentru mulțimea de învățare, ceea ce înseamnă că va ști datele de învățare, dar nu le va putea generaliza la alte date necunoscute.

Numărul neuronilor ascunși reprezintă o problemă esențială în proiectarea unei rețele neuronale, cele mai utilizate metode fiind "Trial and Error", algoritmi evolutivi, căutarea exhaustivă și algoritmi Growing și Pruning. Totuși, aceste metode sunt foarte limitate și consumă mult timp.

În acest capitol sunt analizate structurile rețelelor neuronale și este prezentată o explicație a efectului arhitecturii rețelei neuronale asupra capacității de învățare a acesteia. Pe lângă numărul de straturi ascunse și cel de neuroni ascunși, structura unei rețele neuronale depinde de mulți alți parametri: funcția Cost, funcția de activare și Hyper-parametri [10].

#### **Concluzii:**

În acest capitol sunt prezentate structura rețelei neuronale și efectul numărului de straturi ascunse și a celui de neuroni ascunși asupra capacității de învățare a rețelei. În general, dimensiunea rețelei afectează complexitatea rețelei dar, cel mai important, afectează capacitățile de generalizare ale acesteia.

Sunt discutate mai multe metode utilizate pe scară largă pentru determinarea arhitecturii rețelei neuronale și sunt prezentate punctele slabe ale acestor metode. Am ajuns la concluzia că, până în prezent, nu există o metodă generală care să determine arhitectura unei rețele neuronale pe baza complexității problemei care trebuie rezolvată.

Principala problemă este reprezentată de timpul de învățare și generalizarea rețelei, problemă cu care ne confruntăm în procesul de proiectare a structurii rețelei neuronale. Numărul de straturi ascunse depinde de complexitatea problemei, pentru obținerea unei precizii de clasificare bune. Un număr mare de straturi ascunse poate determina o supra-pregătire a mulțimii de date de învățare.


### **3. Determinarea arhitecturii optime a rețelei neuronale prin utilizarea tehnicilor de grupare**

Acest capitol prezintă o nouă metodă pentru determinarea structurii optime Perceptron multistrat pe baza recunoașterii de tipar și extragerii de date. Folosind tehnici de grupare a mulțimii de date utilizate pentru învățarea rețelei neuronale și pe baza criteriilor date, putem defini o serie de grupări. Rezultatele obținute prin gruparea mulțimii de date de învățare pot fi utilizate ca indicator pentru determinarea nivelului de complexitate a problemei care trebuie rezolvată. Pe baza numărului de grupări obținute, putem determina numărul de straturi ascunse pentru o structură Perceptron cu mai multe straturi (MLP). Acest studiu oferă mai multe posibilități de generalizare a metodei propuse.

Prin utilizarea acestei metode se evită realizarea unei structuri complicate a rețelei neuronale prin setarea unui număr de straturi ascunse mai mare decât este necesar. Pe de altă parte, această metodă evită folosirea unui număr prea mic de straturi ascunse, caz în care rețeaua nu ar putea să obțină performanțe satisfăcătoare. În ceea ce privește numărul de neuroni ascunși, această metodă evită utilizarea unui număr mare de neuroni ascunși deoarece, prin folosirea unui număr de neuroni mai mare decât este necesar, rețeaua va memora tiparele în loc să învețe din mulțimea de date de training [11], afectând astfel capacitatea de generalizare a rețelei neuronale pentru a interpola și extrapola date pe care nu le-a văzut până atunci.

Ideea din spatele acestei metode de grupare este aceea de a împărți mulțimea de date de învățare utilizate pentru învățarea rețelei neuronale folosind metode de recunoaștere a tiparelor [3]. În acest mod se obține o mulțime de clase omogene; în plus, obținem o serie de elemente care nu aparțin niciunui grup. Pe baza informațiilor colectate din gruparea mulțimii de date de învățare, concluzionăm că numărul de grupuri obținute în cazul a cel puțin 90% din formularele de intrare grupate este egal cu număr optim de straturi ascunse pentru o rețea neuronală multistrat. Numărul de grupări trebuie să fie cât mai mic pentru a obține o rețea cu cel mai mic număr posibil de straturi ascunse, reducându-se astfel complexitatea rețelei.

Luând în considerare stabilitatea operațiunii de grupare, inclusiv semnificația prin creșterea valorii distanței de referință, numărul de grupuri obținute nu se modifică, dacă nu sunt luate în considerare cazurile extreme. Cazurile extreme sunt, spre exemplu: dacă folosim o distanță de referință foarte mică, atunci fiecare dintre elementele din mulțimea de date va reprezenta un grup, iar dacă vom considera o distanță de referință foarte mare, atunci toate elementele vor face parte dintr-un singur grup. Distanța de referință este locul în care se taie dendrograma obținută, folosind grupări ierarhice, pentru a forma grupuri.



**Results obtained using the Euclidian distance**

Figure 1: Relația dintre numărul de grupuri care pot fi obținute în funcție de distanța de referință (Euclidiană sau Manhattan) și dendrograma corespunzătoare obținută din analiza imaginilor de la satelitul Landsat.

În această etapă, se rețin următorii parametri: distanța minimă, maximă și medie precum și procentajul formularelor de intrare care sunt sub distanța medie și peste distanța medie. Acești parametri urmează să fie utilizați în etapa de dimensionare a rețelei neuronale. Numărul de grupuri obținute folosind metoda propusă va fi considerat ca fiind numărul optim de straturi ascunse ale rețelei neuronale multistrat.

Figura 2 explică metoda de determinare a structurii optime a MLP.

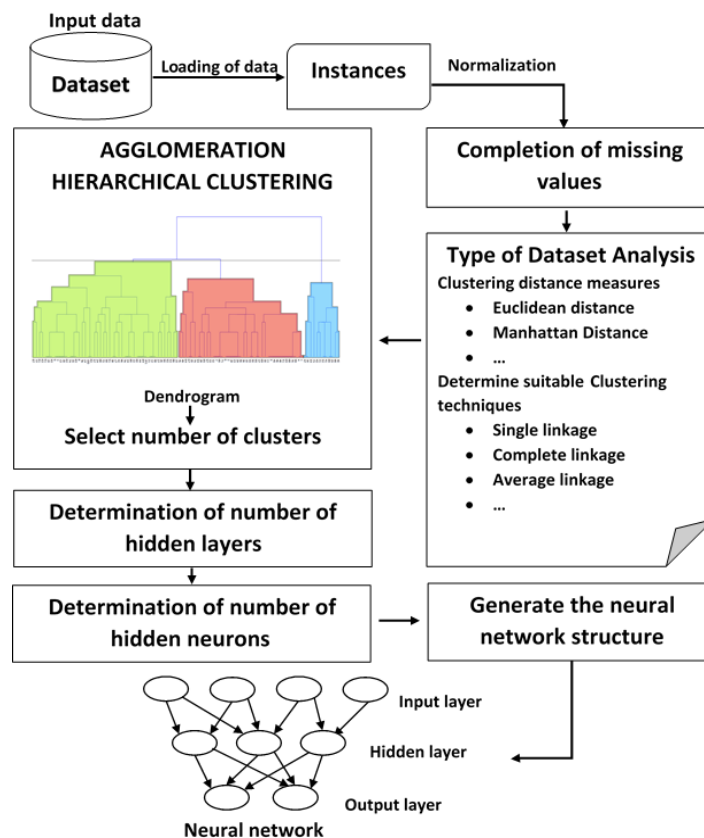


Figura 2. Cadrul propus

După pregătirea mulțimii de date de învățare prin eliminarea zgomotului, a înregistrărilor incomplete și a înregistrărilor care prezintă diferențe mari față de alte date, este necesară o analiză a datelor pentru determinarea măsurii distanței adecvate tipului de date utilizate. Implementarea algoritmului de grupare ierarhica prin aglomerare generează o dendrogramă, care ne va ajuta apoi să definim numărul de grupe, ceea ce va permite determinarea numărului de straturi ascunse.

### 3.1.Etapele metodei utilizate

Metoda propusă încearcă să evalueze nivelul de complexitate al problemei date prin gruparea datelor de învățare a unei rețele neuronale și apoi interpretarea grupului obținut pentru a defini numărul de straturi ascunse. Mulțimea de date folosită pentru învățarea rețelei neuronale va fi grupată folosind metode tradiționale de recunoaștere a tiparului [12] [13]. Gruparea mulțimii de date se va face în baza unui set de criterii (care vor fi menționate ulterior). Împărțirea mulțimii de date va genera un anumit număr de grup. În acest caz, putem alege numărul de grupuri obținute ca fiind egal cu numărul optim de straturi ascunse pentru structura MLP [14]. Această metodă va lua în considerare mai multe criterii care vor fi discutate în acest capitol. Algoritmul folosit pentru proiectarea rețelei neuronale este dezvoltat în mai multe etape.

Paragraful este structurat astfel încât să pună în evidența etapele metodei propuse. Prima etapă este stabilirea mulțimii de date de învățare, pe baza căreia se va realiza trainingul rețelei neuronale. Etapa următoare este stabilirea numărului de neuroni de intrare, care va fi egal cu numărul de caracteristici. Apoi se determină numărul de neuroni de ieșire, care va fi egal cu numărul de clase pentru cazul unei probleme de clasificare sau pentru cazul vectorului caracteristicilor de ieșire. Urmează etapa de determinare a numărului de straturi ascunse, care se bazează pe gruparea mulțimii de date de învățare conform unui set de criterii pentru a obține un număr de grupuri egal cu numărul optim de straturi ascunse. Pentru a face acest lucru este necesar să fie îndeplinite următoarele condiții:

- Gruparea mulțimii de date de învățare trebuie să fie efectuată cu o acoperire de cel puțin 90% din elementele mulțimii de date, deoarece la acest procent avem o reprezentare adecvată a formularelor de date și rezultatul poate fi extrapolat la întreaga mulțime de date.
- Numărul de grupuri obținute trebuie să fie constant, atunci când se crește valoarea distanței de referință, ceea ce indică faptul că gruparea este stabilă. Cazurile extreme nu sunt luate în considerare - o valoare foarte mică a distanței de referință, în care fiecare element al mulțimii de date de învățare este considerat ca un grup sau o valoare relativ mare a distanței de referință, în care toate elementele mulțimii de date de învățare se află într-un singur grup.

Prin aplicarea criteriilor descrise mai sus, numărul de grupuri obținute va fi considerat ca fiind numărul optim de straturi ascunse pentru un MLP. Scopul principal al acestui studiu este de a obține cele mai bune condiții care să conducă la găsirea unui număr de grupuri egal cu numărul optim de straturi ascunse.

Pe baza rezultatelor experimentale s-a observat că numărul de grupuri obținute prin gruparea mulțimii de date de învățare, pe baza condițiilor de mai sus, se apropie de numărul optim de straturi ascunse.

Scopul acestei cercetări este de a determina criteriile adecvate pentru a corela numărul grupurilor obținute cu numărul optim de straturi ascunse, ceea ce necesită un studiu comparativ al măsurării distanțelor de grupare [15]. În această etapă sunt luate în considerare mai multe distanțe relative, cum ar fi gruparea de legătură completă, gruparea cu o singură legătură, gruparea cu distanța medie și procentul formularelor de intrare care sunt grupate sub și peste distanța medie.

### **3.2.Utilizarea metodelor de extragere a datelor**

Metodele de data mining sunt utilizate pentru a analiza mulțimi de date, pentru extragerea informațiilor utile și pentru stabilirea relațiilor pe baza tiparului descoperit la analiza datelor, pentru a găsi soluții pentru anumite probleme. Pe baza informațiilor extrase se pot face predicții rezonabile cu privire la relațiile dintre tiparele descoperite în acele date.

În acest capitol sunt utilizate mai multe tehnici de extragere a datelor pentru analiza mulțimii de date de învățare, în scopul definirii unei arhitecturi optime MLP, printre care grupări, metoda regresiei, algoritmi de clasificare și predicție.

Metoda de grupare ajută la determinarea structurii optime a unei rețele neuronale, în funcție de rezultatele obținute prin gruparea mulțimii de date de învățare a unei rețele neuronale, folosind algoritmul de grupare ierarhică prin aglomerare.

Algoritmul de grupare ierarhică prin aglomerare ajută la analiza datelor pentru crearea grupării pe baza informațiilor obținute din date. Pe baza relației dintre elementele unei mulțimi de date și informațiile extrase din fiecare element, datele sunt adunate în grupuri.

#### **Concluzii:**

Folosind metoda propusă se poate determina arhitectura rețelei neuronale pe baza nivelului de complexitate al problemei de rezolvat.

Folosind tehnici de grupare este posibilă evidențierea mai multor caracteristici comune ale formularelor de intrare, care pot fi clasificate în grupuri (cluster). Gruparea formularelor de intrare generează o serie de factori utili care ajută la determinarea arhitecturii optime a rețelei neuronale.

Pe baza rezultatelor obținute în acest capitol, se observă că algoritmi de grupare folosiți sunt afectați de mai mulți factori care influențează numărul de straturi ascunse obținut, folosind metoda propusă. Cel mai important factor este distanța de referință, precizia valorii acestui factor fiind necesară pentru a obține un număr optim de straturi ascunse.

Studiul comparativ al măsurării distanțelor de grupare acordă metodei propuse mai multă eficacitate și acuratețe datorită selectării perfecte a măsurilor adecvate ale distanței, pentru tehnica de grupare utilizată, care este folosită pentru a determina structura rețelei neuronale MLP.

Studiul comparativ prezentat în această secțiune consolidează această metodă pentru a favoriza diferite tipuri de date de învățare, cum ar fi intervalul, ordinul, categoriile sau combinarea diferitelor tipuri de variabile care îmbunătățesc capacitatea de a recunoaște a grupurilor în mulțimea de date. Acesta îmbunătățește capacitățile de generalizare a metodei propuse.

S-au analizat mai multe mulțimi de date și s-a ajuns la concluzia că rezultatele experimentale obținute validează rezultatele obținute prin metoda de grupare, ceea ce dovedește validitatea metodei propuse.

Comparația metodei propuse cu metodele clasice ne conduce la concluzia că metoda propusă funcționează bine pentru diferitele tipuri de mulțimi de date, fiind mai flexibilă cu diverse tipuri de mulțimi de date, comparativ cu metodele clasice. Metoda propusă se adaptează complexității mulțimilor de date pentru a oferi cele mai bune rezultate, indiferent de dimensiunea mulțimii de date.

Folosind metoda propusă, se reduce timpul de proiectare și efortul în determinarea structurii

rețelei neuronale MLP. Această metodă poate face proiectarea mai simplă și chiar accesibilă unui nespecialist.

#### 4. Determinarea arhitecturii optime a rețelei neuronale folosind tehnici de regresie

Acest capitol prezintă o metodă originală de determinare a arhitecturii optime a unei rețele neuronale (Numărul neuronilor ascunși) utilizând metode de regresie. Prin gruparea mulțimii de date de învățare se obțin o mulțime de parametri care pot fi utili pentru a defini modelele de regresie, în scopul determinării numărului neuronilor din straturile ascunse. Parametrii obținuți din gruparea datelor de învățare pot fi luați ca variabile independente pentru determinarea funcției de regresie. Tehnicile de extragere de date reprezintă un instrument util pentru identificarea și evaluarea tiparelor din datele de învățare pentru a afla nivelul de complexitate al problemei care trebuie rezolvată de rețeaua neuronală, astfel încât să putem prezice structura optimă a unei rețele neuronale. Această metodă funcționează nesupravegheată, spre deosebire de alte metode, fiind mai flexibilă relativ la diferite tipuri de mulțimi de date. Metoda propusă se adaptează complexității mulțimilor de date de învățare pentru a oferi cele mai bune rezultate, indiferent de dimensiunea și tipul mulțimii de date.

Pentru a determina numărul neuronilor ascunși ai unei rețele neuronale, este definit un model de regresie liniară multiplă, bazat pe parametrii obținuți din metoda de grupare descrisă mai sus. În plus, un factor de măsură a calității arhitecturii rețelei este definit pe baza interconectării straturilor.

##### 4.1. Testarea ipotezelor statistice

Testarea ipotezelor statistice [16] este utilizată pentru examinarea parametrilor obținuți prin gruparea ierarhică a mulțimii de date de învățare, cu scopul selectării unui număr de parametri, pentru utilizarea modelului de regresie. Coeficienții de probabilitate ai variabilelor independente (valoarea P) au o valoare mai mică de 0,05 pe baza parametrilor propuși pentru variabilele independente ale modelului de regresie. Analiza F-Test, utilizată pentru analiza varianței, va fi considerată ca dovadă pentru demonstrarea faptului că structura Perceptron multistrat depinde de factorii selectați.

Coeficientul de determinare multiplă și coeficientul de corelație multiplă obținuți [17] în ambele studii sunt apropiați de valoarea 1. Aceasta dovedește validitatea, eficiența modelelor considerate și corectitudinea selecției factorilor incluși în modele.

Datele experimentale obținute cu ajutorul unui program de grupare sunt utilizate pentru a defini funcțiile de regresie pentru calculul numărului de straturi și al celui de neuroni din aceste straturi aparținând unei rețele neuronale MLP. Parametrii obținuți folosind programul de grupare sunt suficienți, în conformitate cu indicatorii statistici, pentru a defini modelele de regresie și pentru a garanta calitatea și acuratețea modelelor de regresie alese. Modelul de regresie liniară multiplă are următoarea formă:

$$f = X \rightarrow Y$$
$$f(X) = w_0 + \sum_{j=1}^n w_j x_j \quad (1)$$

Modelul definit pentru calcularea numărului de neuroni ascunși se bazează pe următorii parametri: valoarea distanței de referință, numărul de grupuri obținute, numărul formularelor de intrare ale rețelei neuronale MLP, numărul elementelor grupate și numărul de neuroni din stratul de intrare. Fiecare model de regresie este format din 4 factori obținuți din parametri



precedenți.

Pe baza rezultatelor obținute din algoritmi folosiți pentru determinarea structurii rețelei neuronale și pe baza informațiilor preluate din exemplele de învățare, se observă că există o relație matematică între parametrii folosiți pentru determinarea structurii rețelei neuronale MLP și rezultatele obținute cu algoritmul de grupare. Mai mult, calitatea structurii rețelei a fost considerată un factor independent. Factorul de evaluare a calității ia în considerare straturile de configurare și interconectare.

Modelele de regresie propuse constau din două modele: primul model fiind folosit pentru a determina numărul de straturi ascunse și al doilea model fiind utilizat pentru a determina numărul neuronilor ascunși.

## 4.2. Etapele metodei utilizate

Metoda regresiei depinde de rezultatele algoritmilor de recunoaștere a modelului, aplicate pe datele utilizate pentru învățarea rețelei neuronale. Metoda caută să definească numărul de straturi ascunse, iar numărul de neuroni ascunși este obținut prin mai multe etape.

După aplicarea etapelor metodei de grupare descrise în capitolul precedent, următoarea etapă este configurarea numărului de neuroni ascunși. Pentru determinarea numărului de straturi ascunse și a celui de neuroni din straturile ascunse, au fost dezvoltate două modele de regresie liniară multiplă, folosind parametrii obținuți în etapele anterioare. În plus, este introdus un factor de măsurare a calității arhitecturii rețelei, care are în vedere straturile de configurare și de interconectare definite în pasul anterior.

Comparând rezultatele obținute folosind metoda regresiei pentru mulțimile de date selectate cu valorile erorilor obținute pentru diferite arhitecturi de rețele neuronale pentru definirea celei mai bune arhitecturi, confirmăm că metoda de regresie propusă poate prezice cel mai bine numărul de straturi ascunse și a celui de neuroni ascunși, pentru o rețea neuronală multistrat.

Rezultatele obținute prin testele experimentale confirmă validitatea metodei de regresie propuse pentru determinarea arhitecturii rețelei neuronale, în baza analizei mulțimii de date selectate.

### **Concluzii:**

Se observă că recunoașterea tiparului joacă un rol important în determinarea structurii optime a rețelei neuronale MLP, pe baza metodei de regresie propuse.

Prin gruparea mulțimii de date putem colecta o mulțime de parametri utili pentru determinarea structurii rețelei neuronale MLP, ca variabile independente utilizate pentru găsirea modelelor de regresie din metoda propusă.

Folosind metoda de regresie propusă pentru a determina structura rețelei neuronale, se constată că mai mulți factori afectează acuratețea rezultatelor. Factorul principal este distanța de referință, care are cea mai mare influență, în comparație cu ceilalți factori. Valoarea distanței de referință trebuie selectată exact pe baza criteriilor definite în capitolul precedent.

Concluzionăm că metoda de regresie propusă pentru determinarea structurii rețelei neuronale MLP, legat de numărul de straturi ascunse și a celui de neuroni din aceste straturi, este viabilă.

Modelul generat folosind metoda de regresie propusă poate fi esențial în aplicații practice și, în cele mai nefavorabile ipoteze, poate oferi numărul inițial de straturi și de neuroni ascunși în aceste straturi în cazul unei rețele neuronale MLP. Bazându-se pe informațiile obținute din mulțimea de date de învățare proiectantul poate reduce sau crește aceste numere.

Acest studiu propune și dezvoltă o nouă strategie de proiectare pentru o rețea neuronală MLP care face ca designul structurii unei rețele neuronale MLP să nu fie supravegheat, ajutând și la reducerea timpului alocat pentru proiectarea acesteia.

## 5. Analiza datelor de învățare pentru îmbunătățirea capacităților de generalizare a arhitecturilor rețelelor neuronale

Acest capitol prezintă o îmbunătățire a capacităților de generalizare, pe baza metodei de grupare, care a fost propusă și prezentată în capitolul 3, pentru a determina structura unei rețele neuronale cu mai multe straturi. Precizia metodei de grupare utilizate necesită selectarea măsurilor distanței de grupare, fiind necesar un studiu comparativ. Metoda de grupare propusă depinde de rezultatele obținute prin gruparea datelor de învățare. Prin urmare, analiza mulțimii de date de învățare este importantă pentru a îmbunătăți capacitățile de generalizare a arhitecturii rețelelor neurale. Datorită diverselor tipuri de mulțimi de date, metodele clasice nu acoperă toate tipurile de mulțimi de date. Metoda propusă este mai flexibilă, în raport cu tipul de date, dimensiunea și numărul de caracteristici.

S-au considerat multe aspecte pentru creșterea capacității de generalizare a metodei propuse, cum ar fi măsurările de distanță și metodele de legătură.

Acest capitol prezintă o îmbunătățire a capacităților de generalizare a arhitecturii rețelei neuronale. Prin compararea rezultatelor diverselor tipuri de mulțimi de date, s-a ajuns la concluzia că metodele clasice nu acoperă toate tipurile de mulțimi de date de învățare. Eficacitatea metodei propuse variază în funcție de variația complexității problemei care trebuie rezolvată. Metoda propusă se poate adapta în funcție de complexitatea problemei și poate avea mai multă flexibilitate cu diferite tipuri de mulțimi de date.

Metoda propusă impune o selecție perfectă a măsurărilor distanței, datorită impactului semnificativ al acestora asupra rezultatelor grupării mulțimii de date de învățare și, prin urmare, măsurările distanței afectează exactitatea arhitecturii rețelei neuronale. În consecință, este necesar un studiu comparativ pentru a determina măsurile adecvate ale distanței. Distanțele metrice (cum ar fi Manhattan și Euclidian) vor fi recunoscute pentru măsurarea distanțelor. Metodele de legătură (cum ar fi gruparea cu legături medii, gruparea cu legătură completă și gruparea cu o singură legătură) utilizate pentru calcularea distanței dintre obiecte, vor fi calculate cu metoda grupării.

Pentru a demonstra capacitățile de generalizare a metodei propuse, selectăm o mulțime de date cu un număr diferit de exemple și funcții. Pentru a acoperi diferite niveluri de complexitate, comparăm precizia de clasificare și eroarea / epoca mulțimilor de date considerate cu rezultatele obținute cu diferite numere de straturi ascunse, până când putem demonstra eficacitatea metodei propuse.

Pe baza rezultatelor obținute se constata ca metoda propusă pentru determinarea numărului de straturi ascunse are cea mai mică valoare de eroare / epocă pentru diferite mulțimi de date. Metoda propusă se adaptează complexității mulțimii de date pentru a oferi cele mai bune rezultate, indiferent de dimensiunea mulțimii de date. Rezultatele dovedesc capacitățile de generalizare a arhitecturii rețelelor neuronale definite folosind metoda propusă.

### **Concluzii:**

Utilizarea tehnicilor de grupare a datelor de învățare poate defini numărul optim de straturi ascunse. Precizia este necesară atunci când se selectează măsurile distanței de grupare, fiind deci necesar un studiu comparativ pentru a efectua o grupare perfectă a mulțimii de date de învățare, în cazul în care acesta afectează exactitatea rezultatelor.

Studiul comparativ pentru determinarea măsurilor distanței adecvate oferă metodei propuse o performanță mai bună pentru gestionarea diferitelor tipuri de date care cresc capacitățile de generalizare a arhitecturii rețelei neuronale.

Metoda propusă dovedește capacitatea de a trata diverse tipuri de mulțimi de date, care îmbunătățesc capacitățile de generalizare a metodei propuse.

## 6. Compararea metodei propuse cu metodele clasice

Proiectarea structurii unei rețele neuronale MLP este o problemă esențială. Până acum nu a fost găsită o teorie general valabilă pentru determinarea structurii unei rețele neuronale MLP, în funcție de complexitatea problemei. Metodele utilizate, în fapt, sunt: algoritmi evolutivi, căutare exhaustivă și algoritmi Growing și Pruning, dar acestea sunt foarte limitate și consumă mult timp [18]. Cu cât numărul neuronilor ascunși este mai mare, cu atât capacitatea unei rețele neuronale de a rezolva problema crește, dar poate fi necesar și un timp de învățare foarte mare. Scăderea numărului de neuroni ascunși poate provoca o îmbunătățire a generalizării rețelei neuronale, dar rețeaua neuronală devine slabă sau nu poate satisface solicitărilor.

În acest capitol, mai multe formule empirice utilizate pentru determinarea numărului de neuroni din straturile ascunse ale unei rețele neuronale MLP vor fi examinate și testate pe o altă mulțime de date de învățare. Aceste metode clasice vor fi, de asemenea, comparate cu metoda propusă. Pentru comparație sunt selectate mai multe formule, utilizate pe scară largă.

S-au utilizat mai multe mulțimi de date, cum ar fi Waveform Database Generator, mulțime de date Image Segmentation, Glass identification, Landsat, Sonar, ECG, QRS, P-wave și T-wave.

Metoda propusă obține cel mai bun procent de precizie pentru diferite mulțimi de date, spre deosebire de metodele clasice. Unele tehnici clasice funcționează bine cu mulțimi de date mici, care au puține elemente de învățare. Alte metode clasice funcționează bine cu mulțimi mari de date, deoarece iau în considerare numărul de date de învățare. Formulele care depind, în principal, de numărul neuronilor de intrare și de ieșire sunt eficiente pentru mulțimi mici de date, dar nu funcționează bine cu mulțimi mari de date, pentru cazul problemelor complexe. Rezultatele erorii / epocii obținute sunt aproape similare cu rezultatul procentului de precizie.

Comparația metodei propuse cu metodele clasice ne conduce la concluzia că metoda propusă funcționează bine pentru diferite tipuri de mulțimi de date, ceea ce înseamnă că metoda propusă este mai adaptată la diferite tipuri de mulțimi de date, față de metodele clasice. Metoda propusă se adaptează complexității mulțimii de date pentru a oferi cele mai bune rezultate, indiferent de dimensiunea acesteia. În unele cazuri, mulțimea de date este aleasă cu o dimensiune mai mare decât cea necesară, ceea ce duce la rezultate negative în cazul folosirii metodelor clasice, dar această problemă este evitată dacă folosim metoda propusă, deoarece se concentrează pe complexitatea problemei care trebuie rezolvată, indiferent de dimensiunea mulțimii de date.

## 7. Concluzii și Contribuții personale

Rețelele neuronale reprezintă un instrument important în clasificarea datelor. Este singura tehnică care permite generalizări bazate pe o mulțime de date care trebuie analizate. Indiferent de arhitectura rețelei neuronale alese și de modul de învățare, numărul de straturi ascunse și numărul de neuroni ascunși sunt determinați, în prezent, empiric, prin testare.

În această teză, am demonstrat importanța tehnicilor de extragere de date pentru determinarea arhitecturii rețelei neuronale. Considerăm că analiza mulțimii de date utilizate pentru învățarea rețelei neuronale poate duce la o arhitectură optimă a rețelei neuronale. Tiparele descoperite în mulțimea de date de învățare pot determina nivelul de complexitate al problemei considerate, astfel putând să definim arhitectura rețelei. În această teză exploatăm tehnicile de extragere de

date pentru analizarea mulțimii de date de învățare pentru determinarea unei metode generale, care se adaptează la toate tipurile de probleme incluse în domeniul rețelei neuronale.

#### **Au fost atinse următoarele obiective:**

1. S-a efectuat o analiză a metodelor utilizate în prezent pentru determinarea arhitecturii rețelei neuronale. Sunt prezentate mai multe metode utilizate pe scară largă pentru a determina arhitectura rețelei neuronale și sunt prezentate punctele slabe ale acestor metode.
2. Determinarea gradului în care structura unei rețele neuronale afectează capacitatea de învățare a acesteia. Analiza a urmărit să definească relația dintre numărul de straturi / neuroni ascunși și complexitatea problemei care trebuie rezolvată de rețeaua neuronală. Analiza s-a extins și asupra modului în care arhitectura rețelei neuronale trebuie să se adapteze pentru a îmbunătăți capacitățile de generalizare a rețelei.
3. Studiul a fost realizat cu scopul de a găsi o modalitate de a exploata tehnicile de extragere de date pentru: a analiza mulțimea de date utilizate pentru învățarea rețelei neuronale, a extrage informații utile și a stabili relații pe baza tiparului descoperit din date, a găsi soluții pentru determinarea arhitecturii optime a rețelei neuronale.
4. Studiul tehnicilor de extragere de date a fost realizat cu scopul de grupare a mulțimii de date folosite pentru învățarea unei rețele neuronale bazată pe tehnici de recunoaștere a tiparului, pentru extragerea caracteristicilor comune și de corelare a numărului de grupuri obținute cu numărul optim de straturi ascunse ale unei rețele neuronale multistrat. Câteva criterii au fost definite în funcție de contextul în care se corelează numărul de grupuri obținut cu numărul optim de straturi ascunse.
5. După determinarea numărului de straturi ascunse, bazat pe metoda de grupare propusă, determinarea numărului de neuroni ascunși devine, de asemenea, necesară. Scopul studiului a fost să selecteze o mulțime de parametri obținuți, folosind metoda de grupare propusă, ceea ce poate fi util în definirea de modele de regresie pentru determinarea numărului de neuroni ascunși. În funcție de testarea statistică a ipotezelor și pe baza analizei F-Test, s-a dovedit că numărul neuronilor ascunși depinde de factorii considerați.

Rezultatele cercetării, care au fost realizate pe mai multe etape, au fost finalizate prin propunerea unei noi metode generale de determinare a arhitecturii optime a rețelei neuronale, folosind metoda de grupare ierarhica prin aglomerare și metoda de regresie.

Utilizarea metodei de grupare ierarhica prin aglomerare poate ajuta la extragerea mai multor caracteristici comune ale formularelor de intrare prin care sunt clasificate datele de intrare în rețeaua neuronală. Folosind metoda de grupare se poate determina un număr apropiat de numărul optim de straturi ascunse ale unei rețele neuronale multistrat.

Acest studiu propune și dezvoltă o nouă strategie de proiectare pentru o rețea neuronală MLP, prin care proiectarea structurii unei rețele neuronale MLP este nesupravegheată și contribuie la reducerea timpului alocat pentru proiectarea rețelei.

Folosind metoda propusă, se reduce timpul de proiectare și efortul de determinare a structurii rețelei neuronale MLP. Această metodă poate face proiectarea mai simplă, mai ușoară și mai accesibilă unui proiectant nespecialist.

Arhitectura optimă a unei rețele neuronale poate fi determinată folosind rezultatele algoritmului de grupare aplicat datelor de învățare. Utilizând metoda de învățare propusă, s-a constatat că există mai mulți factori care afectează numărul de straturi ascunse ale unei rețele neuronale

multistrat. Un astfel de factor este distanța de referință. Precizia acestui factor este importantă în determinarea numărului optim de straturi ascunse.

Utilizând metoda de regresie propusă pentru determinarea structurii rețelei neuronale s-a constatat ca există mai mulți factori care afectează acuratețea rezultatelor. Factorul principal este distanța de referință, care are un efect determinant, în comparație cu ceilalți factori. Valoarea distanței de referință trebuie selectată exact pe baza criteriilor definite în capitolul precedent.

Pentru a arăta viabilitatea acestei metode pentru reprezentare, în cadrul tezei a fost realizat un studiu, prezentat în capitolul 3. Viabilitatea metodei a fost dovedită printr-un studiu comparativ al măsurilor legate de distanța grupurilor, ceea ce oferă metodei propuse mai multă eficacitate și acuratețe, prin selectarea măsurilor legate de distanța adecvată pentru tehnica de grupare, utilizată în determinarea structurii rețelei neuronale MLP.

Din această cercetare se deduce că recunoașterea tiparului are un rol considerabil în determinarea structurii unei rețele neuronale.

În studiul realizat în capitolul 4, experimentele metodei de regresie propuse au fost efectuate conform indicatorilor statistici, care au dovedit că modelul generat folosind metoda de regresie propusă este viabil și poate fi de neînlocuit în aplicații practice.

#### **Au rezultat următoarele concluzii:**

- Testarea ipotezei statistice a dovedit că modelul de regresie este semnificativ. Testarea ipotezei a demonstrat că variabilele independente obținute prin gruparea ierarhică a mulțimii de date de învățare au o relație semnificativă cu variabila dependentă. Prin urmare, există o relație între rezultatele grupării și structura Perceptron multistrat. În consecință, s-a stabilit modelul de regresie.
- Prin acest studiu putem concluziona că metoda de regresie propusă pentru determinarea structurii rețelei neuronale a MLP, în privința numărului de straturi ascunse și a celui de neuroni din aceste straturi, este viabilă.
- Modelul generat folosind metoda de regresie propusă se poate dovedi esențial în aplicații practice și poate furniza cel puțin numărul inițial de straturi și neuroni ascunși din aceste straturi dintr-o rețea neuronală MLP, bazându-se pe informațiile obținute din mulțimea de date de învățare, pe care proiectantul îl poate reduce sau crește.
- Metoda de grupare propusă poate defini structura rețelei neuronale cu rezultate care au o bună precizie. Pentru a îmbunătăți capacitățile de generalizare a metodei a fost necesară o selecție precisă a măsurilor adecvate ale distanței de grupare. Prin urmare, este necesar un studiu comparativ al măsurilor distanței utilizate, legat de gruparea datelor de învățare, pentru a realiza o grupare perfectă, care afectează pozitiv acuratețea rezultatelor metodei propuse.
- Pentru a crește capacitățile de generalizare a metodei propuse, avem nevoie de un studiu comparativ care să determine măsurile distanței adecvate, pentru a îmbunătăți performanța de gestionare a diferitelor tipuri de date de învățare.
- Metoda propusă a dovedit capacitatea de a trata diferite tipuri de mulțimi de date de învățare, care îmbunătățesc capacitățile de generalizare a metodei propuse.
- Comparația metodei propuse cu metodele clasice ne conduce la concluzia că metoda propusă funcționează bine pentru diferitele tipuri de mulțimi de date, ceea ce înseamnă că este mai flexibilă cu diferite tipuri de mulțimi de date, comparativ cu metodele clasice. Metoda propusă se adaptează complexității mulțimilor de date de

învățare, pentru a oferi cele mai bune rezultate, indiferent de dimensiunea mulțimii de date.

### **Contribuțiile acestei teze sunt:**

1. Definierea teoretică a unei metode noi, originale, în determinarea arhitecturii optime a rețelei neuronale prin analiza mulțimii de date de învățare.
2. Una dintre cele mai importante contribuții ale acestei teze este dezvoltarea unui algoritm care determină arhitectura rețelei neuronale în baza complexității problemei de rezolvat.
3. Pentru acest studiu, bazat pe metoda propusă, a fost utilizată și dezvoltată o terță platformă, Weka.
4. Metoda propusă s-a adaptat la complexitatea datelor de învățare pentru obținerea celor mai bune rezultate, indiferent de dimensiunea și tipul mulțimii de date, în comparație cu metodele utilizate în prezent.
5. Un studiu comparativ al metodei propuse cu metodele utilizate în prezent ne conduce la deducerea că metoda propusă funcționează bine pentru diferite tipuri de mulțimi de date, ceea ce înseamnă că metoda propusă este mai flexibilă cu diferite tipuri de mulțimi de date decât alte metode.
6. Studiul comparativ al măsurilor distanței de grupare oferă metodei propuse mai multă eficiență și acuratețe, prin selectarea perfectă a măsurilor de distanță adecvate pentru tehnica de grupare utilizată în determinarea structurii rețelei neuronale.

Rezultatele obținute au fost validate prin publicarea unui număr de 5 articole, din care 4 sunt indexate ISI, iar trei IEEE. Articolele publicate au fost citate de 8 ori.

În cadrul prezentei cercetări au fost prezentate și publicate o serie de lucrări care urmăresc și reflectă diversele etape de cercetare care au fost parcurse. Aceste lucrări sunt:

- 1) Tej, Mohamed Lafif, and Stefan Holban. "Determining Multi-layer Perceptron Structure Using Clustering Techniques." *International Journal of Artificial Intelligence* 17, no. 1 (2019): pp. 139-166.
- 2) Tej, Mohamed Lafif, and Stefan Holban. "Determining neural network architecture using data mining techniques." In *2018 International Conference on Development and Application Systems (DAS)*, pp. 156-163. IEEE, 2018.
- 3) Tej, Mohamed Lafif, and Stefan Holban. "Comparative Study of Clustering Distance Measures to Determine Neural Network Architectures." In *2018 IEEE 12th International Symposium on Applied Computational Intelligence and Informatics (SACI)*, pp. 000189-000194. IEEE, 2018.
- 4) Tej, Mohamed Lafif, and Stefan Holban. "Determining optimal neural network architecture using regression methods." In *2018 International Conference on Development and Application Systems (DAS)*, pp. 180-189. IEEE, 2018.

- 5) Tej, Mohamed Lafif, and Stefan Holban. "Determining Optimal Multi-Layer Perceptron Structure Using Linear Regression." In International Conference on Business Information Systems, pp. 232-246. Springer, Cham, 2019.

## Bibliography

- [1] A. Itamar, D. C. Rose and T. P. Karnowski, "Deep machine learning-a new frontier in artificial intelligence research," *IEEE computational intelligence magazine*, vol. 5, no. 4, pp. 13-18, 2010.
- [2] Y. Zhao, J. Chen and H. Vincent Poor, "Efficient neural network architecture for topology identification in smart grid," in *IEEE Global Conference on Signal and Information Processing (GlobalSIP)*, 2016.
- [3] C. Bishop, *Pattern recognition and machine learning*, Springer, 2006.
- [4] J. Bongard, "Biologically Inspired Computing," *INSPEC Accession Number: 10712660*, vol. 42, no. 4, 2009.
- [5] H. Guanshan, "Neural Network Applications in Sensor Fusion for a Mobile Robot Motion," in *WASE International Conference on Information Engineering*, 2010.
- [6] R. Lovassy, L. T. Kóczy and L. Gál, "Fuzzy neural networks stability in terms of the number of hidden layers," in *IEEE 12th International Symposium on Computational Intelligence and Informatics (CINTI)*, 2011.
- [7] K. Shibata and Y. Ikeda, "Effect of number of hidden neurons on learning in large-scale layered neural networks," in *ICCAS-SICE*, 2009 .
- [8] M. Negnevitsky, *Artificial Intelligence: A Guide to Intelligent Systems*, second ed., 2005.
- [9] Z. Haoyang, M. D. Edwards, G. Liu and D. K. Gifford, "Convolutional neural network architectures for predicting DNA–protein binding," *Bioinformatics*, vol. 32, no. 12, pp. i121-i127, 2016.
- [10] P. B. Z. a. Q. V. L. Ramachandran, "Searching for activation functions," *arXiv preprint arXiv:1710.05941*, 2017.
- [11] Z. Chiyuan, S. Bengio, M. Hardt, B. Recht and O. Vinyals, "Understanding deep learning requires rethinking generalization," *arXiv preprint arXiv:1611.03530*, 2016.
- [12] D. Ian and S. S. Ravi, "Agglomerative hierarchical clustering with constraints: Theoretical and empirical results," in *European Conference on Principles of Data Mining and Knowledge Discovery*, pp. 59-70. Springer, Berlin, Heidelberg, 2005.
- [13] B. Pavel., "A survey of clustering data mining techniques," in *Grouping multidimensional data*, pp. 25-71. Springer, Berlin, Heidelberg, 2006.
- [14] D. Gopikrishna, P. Wang, D. Rangaprakash and B. Wilamowski, "Fully connected cascade artificial neural network architecture for attention deficit hyperactivity disorder classification from functional magnetic resonance imaging data," *IEEE transactions on cybernetics* , vol. 45, no. 12, pp. 2668-2679, 2015.
- [15] S. A. a. a. T. Y. W. A. S. Shirkorshidi, "A Comparison Study on Similarity and Dissimilarity Measures in Clustering Continuous Data," *PLOS ONE*, vol. 10, no. 12, 2015.
- [16] P. Francesc and Y. Vidal., "Wind turbine fault detection through principal component analysis and statistical hypothesis testing," *Energies*, vol. 9, no. 1, p. 3, 2016.
- [17] S. Chatterjee and A. S. Hadi., *Regression analysis by example*, John Wiley & Sons,

2015.

- [18] T. A. J, P. M, D. W. S, M. G. S and E. M. R, "On Predicting the Optimal Number of Hidden Nodes," in , " *2015 International Conference on Computational Science and Computational Intelligence (CSCI)*, 2015.