

**Stelian Stancu**

**MACHINE LEARNING,  
DEEP LEARNING, DEEP NEURAL NETWORK  
în mediul R**

**Teorie și aplicații**

Colecția  
Cibernetică

**Editura ASE  
București  
2020**



**ACADEMIA DE STUDII ECONOMICE DIN BUCUREȘTI**

**Copyright © 2020, Editura ASE**

Toate drepturile asupra acestei ediții sunt rezervate editurii.

**Editura ASE**

Piața Romană nr. 6, sector 1, București, România

cod 010374

[www.ase.ro](http://www.ase.ro)

[www.editura.ase.ro](http://www.editura.ase.ro)

[editura@ase.ro](mailto:editura@ase.ro)

**Descrierea CIP a Bibliotecii Naționale a României**

**STANCU, STELIAN**

**Machine learning, deep learning, deep neural network în mediul R :  
teorie și aplicații / Stelian Stancu. – București : Editura ASE, 2020**

Conține bibliografie

ISBN 978-606-34-0330-9

37

**Editura ASE**

**Redactor, tehnoredactor și copertă: Claudia-Marinela Dumitru**

Autorul își asumă întreaga responsabilitate pentru: ideile exprimate, corectitudinea științifică, originalitatea materialului și sursele bibliografice menționate.

*Întotdeauna, atunci când vrei cu adevărat ceva bun,  
pentru siguranța înfăptuirii, e bine să îl scoți din tine însuți,  
nu să aștepți a se produce din exteriorul tău.*

*Progresul își are loc comun cu lucrul pe care îl desăvârșești,  
căci altfel te-ai pierde în neantul dezamăgirii.*

# Cuprins

Despre autor ..... 13

Cuvânt-înainte..... 15

## Partea I. Artificial Intelligence – Machine Learning – Deep Learning – Neural Network în mediul R

**Capitolul 1. Artificial Intelligence – Machine Learning – Deep Learning –  
Neural Network – Convolutional Neural Network –  
Deep Neural Network în mediul R..... 19**

- 1.1. Artificial Intelligence – Machine Learning – Deep Learning –  
Neural Network – Convolutional Neural Network – Deep Neural Network,  
percepții comune și caracteristici distinctive ..... 19
- 1.2. Învățarea automată (ML) – o abordare pentru realizarea inteligenței  
artificiale ..... 20
  - 1.2.1. Învățarea automată (ML) – categorii și specializare în sarcini..... 20
  - 1.2.2. Învățarea automată (ML) – rol de clasificator de obiecte..... 21
- 1.3. Învățarea profundă/complexă (DL) – o tehnică pentru implementarea  
învățării automate (ML)..... 23
- 1.4. Extragerea automată a caracteristicilor relevante utilizând învățarea  
profundă/complexă (DL) ..... 24
- 1.5. Exemple de aplicare a învățării profunde/complexe (DL) ..... 25
  - 1.5.1. Detectarea obiectelor ..... 25
  - 1.5.2. Analiza textului ..... 25
  - 1.5.3. Traducerea automată ..... 25
  - 1.5.4. Generarea imaginilor pentru legendă (subtitrarea imaginilor) ..... 26
  - 1.5.5. Recunoașterea entităților definite ..... 26
- 1.6. Deep Learning în contextul ML ..... 26

## Partea a II-a. Rețele Neuronale Artificiale (RNA) în mediul R

**Capitolul 2. Perceptronul clasic și perceptronul multistrat  
în mediul R..... 31**

- 2.1. Neuronul artificial versus neuronul biologic ..... 31
- 2.2. Perceptronul simplu, ca formă de rețea neuronală..... 31
  - 2.2.1. Caracteristici ale setului de date ..... 31
  - 2.2.2. Antrenarea/instruirea perceptronului simplu ..... 32

2.2.3. Predicții la nivelul perceptronului simplu, pe setul de date <code>iris</code> .....	37
2.3. Perceptronul multiplu.....	42
2.4. Construirea unei RNA pe noduri și calculul valorilor funcțiilor de combinare și de activare pe fiecare nod, utilizând mediul R.....	44

### **Capitolul 3. Rețele neuronale de tip feed-forward și algoritmul de propagare înapoi a erorii..... 49**

3.1. Propagarea înainte a semnalului, propagarea înapoi a erorii și epocile la nivelul unei RNA.....	49
3.2. Intuiția din spatele unei rețele neuronale profunde/complexe (DL – Deep Learning).....	49
3.3. Etapele implicate în metodologia unei RNA, utilizând R.....	50
3.3.1. Etapele implementării metodologiei RNA.....	50
3.3.2. Implementarea unei rețele neuronale în R.....	56
3.3.3. Aplicații privind construirea unei rețele neuronale în R, bazată pe MLP, folosind setul de date <code>iris</code> .....	57
3.4. Separabilitatea liniară și separabilitatea neliniară la nivelul unei RNA.....	58

### **Capitolul 4. Construirea, antrenarea/testarea, predicția și validarea unei RNA în mediul R..... 60**

4.1. Preprocesarea și standardizarea datelor.....	60
4.1.1. Ciclul de viață al datelor.....	60
4.1.2. Normalizarea datelor utilizând pachetul <code>reshape</code> , funcția <code>rescaler</code> .....	60
4.1.3. Normalizarea datelor utilizând pachetul <code>clusterSim</code> , funcția <code>data.Normalization</code> .....	62
4.2. Construirea unei rețele neuronale, utilizând pachetul <code>neuralnet</code> .....	63
4.2.1. Despre pachetul <code>neuralnet</code> .....	63
4.2.2. Pașii de construire a unei Rețele Neuronale Artificiale, utilizând pachetul <code>neuralnet</code> .....	64
4.2.3. Implementarea unei rețele neuronale în mediul R, utilizând pachetul <code>neuralnet</code> , fără normalizarea datelor.....	66
4.2.3.1. Instalarea pachetului necesar.....	66
4.2.3.2. Crearea unui set de date de antrenare/instruire.....	66
4.2.3.3. Construirea unui clasificator, folosind biblioteca <code>neuralnet</code> .....	67
4.2.3.4. Reprezentarea grafică a unei rețele neuronale.....	67
4.2.3.5. Crearea unui set de date de testare.....	68
4.2.3.6. Previzionarea rezultatelor pentru setul de testare.....	68
4.2.3.7. Convertirea probabilităților în clase binare.....	68
4.2.3.8. Aplicații propuse spre analiză, utilizând pachetul <code>neuralnet</code> .....	68
4.3. Construirea unei rețele neuronale, utilizând pachetele <code>clusterGeneration</code> , <code>nnet</code> , <code>neuralnet</code> , <code>RSNNS</code> și <code>mlp</code> .....	71

4.4. Construirea unei rețele neuronale, utilizând pachetele ISLR și neuralnet.....	72
4.5. Model de rețea neuronală în mediul R, utilizând datele din cereals.csv – construire, antrenare/testare, predicție și validare .....	73
<b>Capitolul 5. Rețele neuronale recurente (feedback) în mediul R.....</b>	<b>83</b>
5.1. Rețele neuronale de tip Hopfield.....	83
5.1.1. Activarea unei rețele neuronale de tip Hopfield .....	83
5.1.2. Învățarea la nivelul unei rețele Hopfield, utilizând regula lui Hebb .....	87
5.2. Aplicații ale rețelelor neuronale de tip feed-back (recurente), utilizând mediul R .....	92
<b>Capitolul 6. Memorii (auto)asociative în mediul R.....</b>	<b>96</b>
6.1. Caracterizarea memoriilor (auto)asociative .....	96
6.2. Rețele neuronale de tip Hamming și MAXNET.....	96
6.2.1. Rețeaua neuronală de tip Hamming .....	96
6.2.2. Rețeaua neuronală de tip MAXNET .....	98
6.3. Mecanismul de funcționare a unei memorii asociative bidirecționale (MAB) .....	101
6.4. Crearea și antrenarea unei memorii (auto)asociative – cu funcția assoz ....	102
6.5. Crearea și antrenarea unei memorii (auto)asociative – cu funcția bam.....	105
6.5.1. Modele aditive generalizate pentru seturi de date foarte mari .....	105
6.5.2. Sintaxa și interpretarea argumentelor .....	105

## Partea a III-a. Machine Learning versus Deep Learning în mediul R

<b>Capitolul 7. Învățarea automată supervizată, semisupervizată și nesupervizată în mediul R .....</b>	<b>117</b>
7.1. Introducere .....	117
7.2. Aspecte teoretice generale.....	117
7.3. Învățarea automată supervizată/supravegheată (Supervised Machine Learning) .....	118
7.4. Învățarea automată nesupervizată/nesupravegheată (Unsupervised Machine Learning).....	120
7.5. Învățare automată semisupervizată/semisupravegheată sau prin reîntărire (consolidare) .....	122
7.6. Evaluarea metrică a performanțelor unui model bazat pe rețele neuronale artificiale.....	123
7.6.1. Metode de evaluare folosite în alegerea unui model în general.....	123
7.6.2. Caracteristici generale ale evaluării unui model bazat pe RNA .....	124
7.6.3. Matricea de confuzie.....	125
7.6.4. Rata adevărat-pozitiv (True-Positive, adică TP) .....	124

7.6.5. Rata adevărat-negativ (True-Negative, adică TN).....	126
7.6.6. Precizia (accuracy).....	126
7.6.7. Precizia (corectitudinea) și selecția .....	126
7.6.8. Scorul F.....	126
7.6.9. Curba caracteristică a funcționării receptorului (Receiver Operating Characteristic – ROC).....	127
7.6.10. Aplicație privind evaluarea metrică a performanțelor unui model, utilizând R. Aplicație pe setul de date GermanCredit .....	127
7.7. Suport pentru Mașini Vector (Support Vector Machines-SVM) .....	129
7.7.1. Prezentarea unui SVM .....	129
7.7.2. Caracteristici de funcționare ale receptorului (ROC), în cazul unui SVM.....	130
7.8. Implementarea învățării la nivelul unei RNA, utilizând mediul R.....	131
7.8.1. Implementarea învățării la nivelul unei RNA, utilizând librăriile neuralnet și MASS .....	131
7.8.2. Învățarea competitivă și învățarea în rețele kohonen (SOM), caracteristici și algoritmi asociați .....	136
7.8.3. Implementarea învățării nesupervizate la nivelul unei RNA, utilizând librăria kohonen din mediul R .....	139

<b>Capitolul 8. Învățarea automată (ML) și algoritmi de tip Machine Learning în mediul R.....</b>	<b>142</b>
8.1. Pașii de pregătire și aplicare a învățării automate (ML) pe un set de date .....	142
8.1.1. Instalarea pachetelor de lucru și a seturilor de date .....	142
8.1.1.1. Instalarea pachetelor de lucru și a seturilor de date inițiale.....	142
8.1.1.2. Crearea setului de date de validare .....	142
8.1.2. Rezumatul statistic al setului de date, summary () .....	143
8.1.3. Vizualizarea setului de date .....	143
8.1.4. Evaluarea algoritmilor .....	144
8.1.4.1. Cadrul automat de testare și evaluare a modelelor .....	144
8.1.4.2. Construirea de modele .....	145
8.1.5. Selecția celui mai bun model .....	146
8.1.6. Realizarea de predicții.....	146
8.2. Gruparea primară a algoritmilor de tip Machine Learning .....	146
8.2.1. Algoritmi de învățare supervizată/supravegheată.....	146
8.2.2. Algoritmi de învățare nesupervizată/nesupravegheată .....	147
8.2.3. Algoritmi de învățare semisupervizată/semisupravegheată .....	148
8.3. Prezentare generală a algoritmilor de tip Machine Learning (ML).....	149
8.3.1. Algoritmi bazați pe similitudini .....	149
8.3.1.1. Algoritmi de tip ML pentru regresie .....	149
8.3.1.2. Algoritmi bazați pe instanțe .....	150
8.3.1.3. Algoritmi de regularizare .....	150
8.3.1.4. Algoritmi bazați pe arbori de decizie .....	151
8.3.1.5. Algoritmi Bayes-ieni .....	152

8.3.1.6. Algoritmi de clustering .....	152
8.3.1.7. Algoritmi de învățare bazați pe reguli de asociere .....	153
8.3.1.8. Algoritmi bazați pe rețele neuronale artificiale .....	153
8.3.1.9. Algoritmi de tip Deep Learning-DL (de învățare profundă) ...	154
8.3.1.10. Algoritmi de reducere a dimensionalității .....	155
8.3.1.11. Algoritmi de asamblare.....	156
8.3.1.12. Alți algoritmi de tip Machine Learning.....	157
8.4. Pachete de top din mediul R utilizate în sfera Machine Learning.....	157

## **Capitolul 9. Învățarea complexă/profundă (Deep Learning-DL)**

### **la nivelul unei rețele neuronale complexe/profunde**

#### **(Deep Neural Network – DNN) în mediul R .....**

<b>9.1. Caracteristici generale .....</b>	<b>160</b>
<b>9.2. Implementarea Deep Learning, utilizând pachetul keras .....</b>	<b>160</b>
9.2.1. Importanța Deep Learning (DL) .....	160
9.2.2. Instalarea pachetelor de lucru.....	162
<b>9.3. Implementarea rețelei Deep Neural Network (DNN),</b>	
<b>utilizând pachetul keras .....</b>	<b>163</b>
9.3.1. Antrenarea rețelei DNN, utilizând pachetul keras .....	163
9.3.2. Reglarea modelului DNN.....	164
9.3.3. Capacitatea modelului DNN .....	164
9.3.4. Normalizarea datelor în modelul DNN, utilizând pachetul keras...	165
9.3.5. Suport pentru Mașini Vector (SVM – Suport Vector Machine)	
în contextul DNN.....	168
<b>9.4. Implementarea unei rețele Deep Neural Network (DNN),</b>	
<b>utilizând pachetul darch .....</b>	<b>168</b>
<b>9.5. Implementarea rețelei Deep Neural Network (DNN),</b>	
<b>utilizând alte pachete specifice .....</b>	<b>169</b>
9.5.1. Utilizarea pachetului mlbench, cu setul de date	
despre cancerul de sân, BreastCancer .....	169
9.5.2. Utilizarea pachetului deepnet, cu setul de date	
despre cancerul de sân, BreastCancer .....	170
9.5.3. Utilizarea pachetului neuralnet, cu setul de date	
despre cancerul de sân, BreastCancer .....	171
9.5.4. Utilizarea pachetului H2O, cu setul de date	
despre cancerul de sân, BreastCancer .....	173
9.5.5. Utilizarea pachetului mnist, pentru recunoașterea imaginilor .....	174
9.5.6. Utilizarea pachetului mxnet, cu setul de date	
despre cancerul de sân, BreastCancer .....	176
9.5.7. Utilizarea pachetului tensorflow, cu setul de date	
despre cancerul de sân, BreastCancer .....	177



## Partea a IV-a. Reducerea dimensionalității versus clasificare. Aplicații Machine Learning – Deep Learning – Deep Neural Network în mediul R

<b>Capitolul 10. LDA (Linear Discriminant Analysis) și PCA (Principal Component Analysis).....</b>	<b>187</b>
10.1. LDA ca tehnică de reducere a dimensionalității și totodată un algoritm de clasificare .....	187
10.1.1. Introducere în LDA.....	187
10.1.2. LDA ca algoritm de clasificare .....	188
10.1.3. LDA ca tehnică de reducere a dimensionalității.....	189
10.1.4. Rezultate comparative obținute din cele două abordări.....	191
10.2. PCA ca tehnică de reducere a dimensionalității și totodată un algoritm de clasificare .....	191
10.2.1. Introducere în PCA .....	192
10.2.2. PCA ca algoritm de clasificare.....	192
10.2.3. Structura spațiului componentelor principale.....	193
10.2.4. Coduri R în spațiul componentelor principale .....	193
<b>Capitolul 11. Aplicații Machine Learning – Deep Learning – Deep Neural Network în mediul R .....</b>	<b>199</b>
11.1. Elaborarea unei rețele neuronale utilizând pachetul <code>nnet</code> din mediul R ....	199
11.2. Utilizarea pachetelor <code>nnet</code> și <code>neuralnet</code> pentru a elabora rețele neuronale de tip feed-forward .....	202
11.3. Utilizarea pachetului <code>rnn</code> pentru a elabora rețele neuronale recurente .....	207
11.4. Realizarea de predicții pe serii de timp, utilizând pachetele <code>forecast</code> și <code>smooth</code> din R.....	213
11.5. Implementarea rețelelor neuronale complexe/profunde (DNN) de tip Boltzman Machine. Prezentarea pachetului <code>BoltzMM</code> .....	216
11.6. Implementarea rețelelor neuronale complexe/profunde (DNN), utilizând pachetul <code>deepnet</code> .....	220
11.6.1. Prezentarea pachetului <code>deepnet</code> .....	220
11.6.2. Învățarea profundă (DL) pentru predicția cursului de schimb leu-euro .....	223
11.7. Aplicații la nivelul Suport Vector Machine (SVM), utilizând pachetul <code>e1071</code> .....	225
<b>Bibliografie .....</b>	<b>231</b>

## Despre autor

---

Absolvent (1991) al Academiei de Studii Economice din București, Facultatea Cibernetică, Statistică și Informatică Economică; Doctor în Științe Economice – specializarea Cibernetică Economică (1996), licențiat (1998) al Universității București, Facultatea de Matematică, licențiat în drept (2011), cu specializare în științe penale și criminalistică, licențiat în psihologie (2016), cu specializare în psihodiagnoză cognitivă și consiliere psihologică, stagii de pregătire profesională în Göteborg, Suedia (1993), Debe, Polonia (1994, 1995), Olsztyn, Polonia (1996), Praga, Cehia (1998, 2005, 2009), Paris, Franța (2001, 2005, 2007, 2009, 2011, 2012, 2014, 2017, 2019), Barcelona, Spania (2002, 2004, 2009, 2018), Londra, Anglia (2002, 2003, 2006, 2011, 2019), New York, Carolina de Nord, S.U.A. (2002, 2014), Strasbourg, Franța (2002, 2015), Viena, Austria (2003, 2005, 2007, 2012, 2018), München, Germania, (2003, 2009, 2014), Roma, Italia (2003, 2005, 2008, 2014, 2018), Le Mans, Franța (2004, 2017), Milano, Florența, Italia (2005, 2016), New York, Washington, Seattle, U.S.A. (2006, 2011, 2016), Madrid, Barcelona, Spania (2006, 2009, 2015, 2018), Copenhaga, Danemarca (1993, 2008, 2017), Londra, Kent, Anglia (2009), Istanbul, Turcia (2009, 2012, 2015, 2018), Veneția, Italia (2009, 2013, 2018), Sao Paulo, Brazilia (2010), Atena, Grecia (2009, 2011, 2013, 2015, 2017, 2019), Helsinki, Finlanda (2012, 2015, 2019), Shanghai (2012, 2017), Singapore (2013, 2018), Kuala Lumpur (2013, 2018).



**Prof. univ. dr. Stelian STANCU**

Profesor universitar în cadrul Facultății Cibernetică, Statistică și Informatică Economică, Departamentul de Informatică și Cibernetică Economică; profesor titular la disciplinele Machine Learning, Data Science, Data Analysis, Econometrie, Microeconomie cantitativă, Microeconomia incertitudinii, Macroeconomie cantitativă avansată, Economia Informației, Decizii Economice în Condiții de Risc și Incertitudine, Managementul Riscurilor Macroeconomice, Teoria Jocurilor și Negocierii, Tehnologii disruptive.

Profesor universitar asociat în cadrul Universității București, Facultatea de Administrație și Afaceri, profesor la disciplinele Decizii Economice în Condiții de Risc și Incertitudine, Metode statistice și decizionale în administrația publică.

Profesor universitar asociat în cadrul Universității MEDIA, Facultatea de Managementul Afacerilor, profesor la disciplina Proiecte și Jocuri de Conducere.

Profesor universitar asociat în cadrul Universității Europei de Sud-Est LUMINA, Facultatea de Administrarea Afacerilor, profesor la disciplinele Statistică și Econometrie.

Autor sau coautor a peste 40 tratate, monografii și cărți de specialitate, în domeniul economiei cantitative, dintre care enumerăm câteva titluri: *Rețele neuronale artificiale. Teorie și aplicații*, *Macroeconomie cantitativă avansată*, *Microeconomie. Teorie și aplicații*, *Macroeconomie. Teorie și aplicații*, *Introducere în econometrie, utilizând EViews*, *Cibernetică economică. Teorie și aplicații*, *Teoria portofoliilor cu aplicații pe piața financiară*, *Teoria jocurilor pentru economiști*, *Teoria echilibrului general. Teorie și aplicații*, *Managementul proiectelor*, *Metode și tehnici de planificare a proiectelor*, *Metode și tehnici de conducere. Teorie și aplicații*, *Statistica. Teorie și aplicații*, *Economia informației. Teorie și aplicații*, *Matematică. Teste de verificare finală*, *Modelarea matematică a sistemelor și proceselor de conducere. Teorie și aplicații*, *Modelarea cibernetică a fenomenelor economice*, *Decizii economice în condiții de incertitudine cu aplicații pe piața financiară*, *Teoria contractelor. Negocierea și derularea contractelor economice*, *Competiția pe piață și echilibrul economic*, *Flexibilitate și securitate pe piața românească a muncii etc.*

## Cuvânt-înainte

---

În ultimii ani, Machine Learning (ML) și, în special, subcomponenta sa Deep Learning (DL), au înregistrat progrese impresionante. Tehnicile dezvoltate în aceste două domenii sunt acum capabile să analizeze și să învețe din cantități uriașe de exemple din lumea reală într-un format diferit. Deși numărul algoritmilor de învățare automată este extins și în creștere, implementările lor prin cadre și biblioteci sunt, de asemenea, extinse și în creștere. Dezvoltarea software în acest domeniu este rapidă cu un număr mare de software open-source provenind din mediul academic, industrie, start-up-uri sau comunități open-source mai largi.

Data mining (DM) este etapa principală a procesului de descoperire a cunoștințelor care urmărește să extragă informații interesante și potențial utile din date. Deși în timpul acestei lucrări, termenul „extragere de date” este orientat în primul rând către minarea de date la scară largă, multe tehnici care funcționează bine pentru seturi de date la scară largă pot fi, de asemenea, aplicate în mod eficient la seturi de date mai mici. Minerirea datelor poate servi drept fundament pentru inteligența artificială și învățarea mașinilor. Multe tehnici în această direcție pot fi grupate într-unul din următoarele câmpuri:

Inteligența artificială (AI – Artificial Intelligence) este orice tehnică care își propune să permită calculatoarelor să imite comportamentul uman, inclusiv învățarea mașinii, procesarea limbajului natural (NLP), sinteza limbajului, viziunea computerului, robotica, analiza senzorilor, optimizarea și simularea.

Machine Learning (ML – învățarea automată) este un subset de tehnici de AI care permite sistemelor informatice să învețe din experiența anterioară (adică din observațiile de date) și să-și îmbunătățească comportamentul pentru o anumită sarcină. Tehnicile ML includ Support Vector Machines (SVM), arbori de decizie, învățare Bayes, k-means clustering, reguli de asociere, regresie, rețele neuronale și multe altele.

Rețelele neuronale sau NN-urile artificiale sunt un subset de tehnici de ML, ce au ca sursă de inspirație neuronul biologic. Acestea sunt de obicei descrise ca fiind o mulțime de unități interconectate, numite neuroni artificiali, organizate în straturi.

Învățarea profundă (DL) este un subset de NN-uri care face posibil calculul la nivel de NN multistrat. Arhitecturile tipice DL sunt rețelele neuronale profunde (DNN), rețelele neuronale convoluționale (CNN), rețelele neuronale recurente (RNN), rețelele generative adverse (GAN) și multe altele.

Lucrarea de față *Machine Learning, Deep Learning, Deep Neural Network în mediul R. Teorie și aplicații* este concepută în ideea de a veni în sprijinul tuturor celor care doresc să cunoască aspecte mai mult sau mai puțin analitice referitoare la învățarea automată și învățarea profundă, în contextul rețelelor neuronale profunde, din perspectiva aplicării rețelelor neuronale.

În acest context, materialul este structurat pe 11 capitole. Aplicațiile rezolvate au fost concepute în scopul de a explica conceptele fundamentale prezentate și, totodată, pentru înțelegerea în profunzime a aplicării acestora în modelarea economică și alte domenii. Și nu în ultimul rând, aplicațiile propuse au fost realizate în scopul fixării cunoștințelor dobândite.

Pe lângă cele 11 capitole de substanță, lucrarea este completată, de asemenea, de grafice, interpretări ale rezultatelor, care ajută la înțelegerea și clarificarea noțiunilor teoretice prezentate.

Avem deplina convingere că parcurgând conținutul acestei lucrări, studenții vor putea duce cu succes la capăt examenele bazate pe elemente specifice prezentate, tinerii doctoranzi vor găsi suficiente elemente utile în pregătirea unor teze conținând aspecte de noutate maximă, iar toți ceilalți interesați de acest material vor găsi suficiente informații care să atingă latura intelectuală a fiecăruia dintre noi.

În consecință, lucrarea *Machine Learning, Deep Learning, Deep Neural Network în mediul R. Teorie și aplicații* este recomandată atât studenților care au în planul de învățământ discipline având cuvinte-cheie din titlul acestei lucrări, cât și cercetătorilor și celor interesați de aspecte cât mai variate legate de acest domeniu.

Pentru cei interesați de cunoașterea și a altor laturi ale Machine Learning, Deep Learning, Deep Neural Network în mediul R, bibliografia prezentată constituie un bun ghid în acest sens.

Totodată, doresc să mulțumesc anticipat tuturor celor care prin sugestiile și observațiile pe care le vor aduce, vor face ca această lucrare să poată fi perfecționată, întrucât de perfectibilitatea sa sunt întru-totul conștient.

Sesizările pot fi trimise pe una din adresele de e-mail [stelian.stancu@csie.ase.ro](mailto:stelian.stancu@csie.ase.ro) sau [stelian\\_stancu@yahoo.com](mailto:stelian_stancu@yahoo.com).

Martie 2020

Autorul