

Razvoj umjetnih neuronskih mreža za predviđanje minimalnog tlaka miscibilnosti nafte i ugljičnog dioksida (CO₂)

A. B. Nezhad, S. M. Mousavi i S. Aghahoseini

IZVORNI ZNANSTVENI ČLANAK

Utiskivanje plina pod uvjetima miješanja je najraširenija metoda povećavanja iscrpka nafte, a njegova je primjena sve uočljivija u proizvodnji nafte diljem svijeta. Određivanje minimalnog tlaka miscibilnosti (MMP), kao glavnoga parametra u ovim projektima, je problem bez poznatog izravnog rješenja. Dostupne eksperimentalne metode oduzimaju mnogo vremena, a isto tako ni ne postoji neka univerzalna metoda. Dosad su istraživači pokušavali naći parametarsku korelaciju između različitih izravno mjerljivih parametara poput sastava injektiranog plina, temperature ležišta i sastava fluida u ležištu. Međutim, radi složene prirode ove pojave, predložene korelacije nisu točne ni pouzdane. Napravljeni su pokušaji korištenja umjetnih neuronskih mreža (ANNs) za utvrđivanje odnosa, koji možda postoje između MMP, plina i sastava ležišnog fluida i temperature ležišta. Arhitektura mreže temeljene na radijalnoj baznoj funkciji (RBF) uspješno je korištena za predviđanje CO₂ MMP (minimalni tlak miscibilnosti nafte i CO₂).

Ključne riječi: minimalni tlak miscibilnosti (MMP), umjetna neuronska mreža (ANN), radijalna bazna funkcija (RBF)

1. Uvod

Utiskivanje plina pod uvjetima miješanja je među najčešće korištenim metodama povećanja iscrpka nafte, a njegova je primjena sve uočljivija u proizvodnji nafte diljem svijeta. Jedan od važnih pojmova povezanih s opisom procesa utiskivanja plina pod uvjetima miješanja je minimalni tlak miješanja (ili MMP). Kod tog tlaka, injektirani plin i nafta u ležištu postaju miscibilni višestrukim kontaktom, a proces istiskivanja postoje vrlo učinkovit. MMP je također važan parametar u projektu plana izvedbe utiskivanja plina pod uvjetima miješanja. Logička podloga iza određivanja MMP-a za određeni projekt utiskivanja plina pod uvjetima miješanja je balansiranje između velike proizvodnje nafte i smanjenja troškova proizvodnje. Ukoliko je tlak utiskivanja prenizak, istiskivanje bi svejedno bilo dvofazno nemiscibilno te bi stoga lokalna učinkovitost istiskivanja bila ispod željene razine. Ukoliko je tlak previsok, iako bi istiskivanje postalo miscibilno višestrukim kontaktom, i pridobivanje nafte bi dostiglo željenu razinu, trošak stlačivanja injektiranog plina bio bi veći od potrebnog. Zato je potrebno naći optimalan tlak, a taj tlak je MMP. Stoga je točna procjena MMP-a za proces injektiranja miscibilnoga plina od velikog interesa za naftnu industriju. Tradicionalno MMP se određuje ili numerički ili eksperimentalno. Postoji nekoliko načina eksperimentalnog mjerenja MMP-a. Istiskivanje iz cijevi malog promjera jedna je od najrasprostranjenijih metoda te je prihvaćena kao standard za mjerenje MMP-a u naftnoj industriji. Druge eksperimentalne metode za mjerenje MMP-a su mjerenje minimalnog tlaka miscibilnosti na principu dizanja plinskog mjehurića i metoda VIT (Vanishing Interfacial Tension – nestajanje međufazne napetosti).

Temeljeno uglavnom na podacima testa istiskivanja nafte iz cijevi malog promjera, razvijen je niz empiričkih korelacija MMP-a.^{1,9,21} Prvi doprinos razvoju MMP korelacija dali su Benham et al.² Njihova korelacija osniva se na izračunatoj kritičnoj točki sastava izabranih višekomponentnih sustava koji su pojednostavljeni u tri pseudokomponente. Općenito, MMP korelacije mogu prilično dobro odrediti predviđanja MMP-a za raspon sastava nafte i plina u kojima su te korelacije razvijene, a ujedno MMP korelacije poprimaju različite oblike ovisno o tome radi li se o CO₂, CH₄, N₂ ili mješavini plina. Ne postoji sveobuhvatna MMP korelacija koja sustavno predviđa MMP za proizvoljne mješavine nafte i plina.

Alternativni pristup parametarskom modeliranju je primjena umjetnih neuronskih mreža (ANN). Prošlih su se desetljeća umjetne neuronske mreže prometnule u moćan alat za modeliranje složenih sustava. Ove mreže su nealgoritamske, analogne, distributivne i masivne paralelne metode obrade informacija koje su se dokazale kao snažan alat za raspoznavanje uzorka. Budući da obrađuju podatke i uče na paralelan i distributivan način, sposobne su otkriti vrlo složene odnose između nekoliko varijabli, koje su odabrane kao ulaz u mrežu. Kao "model-free" procjena funkcije, neuronske mreže mogu mapirati ulaz u izlaz, bez obzira na složenost međusobnih veza. Stoga se ova metoda može koristiti za predviđanje CO₂ MMP zbog vrlo složene prirode koncepta miscibilnosti. U ovom su radu prikazana mjerenja CO₂ MMP-a za široki raspon ulaznih parametara. Nakon toga se ustroj mreže temeljene na radijalnoj baznoj funkciji (RBF) primjenjuje za predviđanje MMP-a kao funkcija sastava plina, temperature ležišta i sastava nafte.

2. Analize neuralne mreže

Proteklih godina porastao je interes za proučavanje mehanizama i strukture mozga. To je dovelo do razvoja ANN modela računanja za rješavanje kompleksnih problema. Sposobnost neuralne mreže da procijeni svaki složeni funkcionalni odnos, čini nepotrebnim odabir prikladne jednadžbe regresije za određenu primjenu. ANN su same po sebi paralelne i imaju sposobnost učenja nelinearnih odnosa, koji mogu postojati između serije ulaza i izlaza. Dizajn kontrolirane neuralne mreže može se izvesti na različite načine. Najpopularnije su višeslojne unaprijedne neuronske mreže. Ungar et al.(1990) ističu da su ograničenja ovakvih mreža njihovo sporo učenje (velik broj iteracija prije konvergancije), brzo zaboravljanje zbog rijetko navedenih primjera i nedostatka početnog elementarnog znanja.¹⁴

U ovom je radu korištena RBF neuronska mreža, sa slojevima bez povratnih veza (Sl.1). Mreže temeljene na radijalnoj baznoj funkciji mogu tražiti više neurona nego standardne unaprijedne neuronske mreže s povratnim postupkom, ali često se one mogu dizajnirati u djeliću vremena potrebnog za uvježbavanje standardnih unaprijednih mreža. One najbolje rade kada je na raspolaganju više vektora za uvježbavanje.¹⁵

Treba primijetiti da je izraz za ulaznu mrežu neurona radijalne bazna funkcije (radbas) različit od drugih neurona. Tu je mrežni ulaz u radbas transformacijsku funkciju vektor udaljenosti između vektora težine w i vektora ulaza p , pomnoženo s odklonom b . (Okvir $\|$ udaljenost $\|$ na toj slici prima vektor ulaza p i ulaz jednog retka matrice težina i daje skalarni produkt dvaju redaka. Transformacijska funkcija za neuron radijalne bazne funkcije je:

$$\text{Radbas}(n) = e^{-n^2} \quad (1)$$

MATLAB funkcija korištena u ovom radu je *newrb*. Funkcija *newrb* iterativno kreira mrežu temeljenu na radijalnoj baznoj funkciji dodavanjem jednog neurona u svakoj iteraciji. Neuroni se pribrajaju u mrežu dok suma kvadrata pogreške ne padne ispod ciljane pogreške ili dok se ne dostigne maksimalni broj neurona. Poziv za tu funkciju (funkcijski poziv) je

$$\text{net} = \text{newrb}(P,T,GOAL,SPREAD) \quad (2)$$

Funkcija *newrb* uzima matrice vektora ulaza i ciljnih vektora P i T i parametre oblikovanja $GOAL$ i $SPREAD$ i vraća željenu mrežu.⁶

3. Analize procedura

• Prikupljanje podataka:

Kako bi se načinio ANN za predviđanje CO₂-nafta MMP, napravljena je baza pouzdanih eksperimentalnih podataka. Skupovi podataka prikupljeni su iz navedenih radova i članaka.^{1,3,4,17,18,5,12,10,16,6,8,11,7,19} Na kraju je prikupljeno i korišteno 179 grupa podataka za ANN modeliranje MMP-a.

• Ulazni parametri:

Za modeliranje pojava nastalih kod neuralnih mreža od presudne je važnosti odabir ulaznih parametara.

Ulazni podatci za mrežu trebaju biti izabrani vrlo pažljivo ukoliko se očekuje dobivanje najboljih rezultata. Ulazne varijable trebaju odražavati osnovnu fiziku procesa koji se analizira. Mnogi istraživači su raspravljali o parametrima koji utječu na MMP, a napravljeno je i mnogo korelacija.^{1,9,21,3,4,17,13,20}

Stoga su, na osnovu primjera iz literature i dostupnih podataka, izabrani sljedeći parametri za uporabu u MMP modeliranju korištenjem ANN: sastav ležišne nafte (hlapljivost, srednji i molni udjel C₅₊ i molekularna težina C₅₊), temperatura ležišta i CO₂ sastav plina (CO₂, hlapljivost, srednji i molni udjeli C₅₊). Molni udjel C₅₊ plina i volatilni udjel nafte se ne uzimaju u obzir zato što su zavisne varijable.

• Arhitektura mreže

Slika 1 prikazuje arhitekturu mreže. Sastoji se od 3 sloja. Prvi sloj je ulazni sloj i broj čvorišta jednak je dimenziji ulaznoga vektora. U ovoj studiji on je 7. Drugi sloj je skriveni sloj, sastavljen je od nelinearnih jedinica koje su izravno spojene za sva čvorišta ulaznog sloja. Aktivacijske funkcije zasebnih jedinica u skrivenom sloju određuju se Gausovim funkcijama. Izlazni sloj sastoji se od zasebne linearne jedinice, a njegov izlaz je MMP. Jedinici parametri koje u ovoj mreži treba uvježbati su linearne težine u izlaznom sloju.

• Uvježbavanje mreže

U ovom je radu za modeliranje minimalnog tlaka miscibilnosti (MMP) s RBF algoritmom, korišten MATLAB toolbox. Za modeliranje je korištena funkcija *newrb*. Parametri mreže postavljeni su ručno kako bi se smanjila prosječna relativna pogreška (ARE) i srednja apsolutna relativna pogreška (AARE) i poboljšao koeficijent korelacije R . Konačni parametri mreže su sljedeći:

- broj neurona u skrivenom sloju je 100
- *SPREAD* radijalne bazne funkcije je 41
- *GOAL* je 10⁻⁶

$$\text{ARE} = \frac{1}{n} \sum \left(\frac{\text{MMP}_{\text{Predicted}} - \text{MMP}_{\text{Experimental}}}{\text{MMP}_{\text{Experimental}}} \times 100 \right) \quad (3)$$

$$\text{AARE} = \frac{1}{n} \sum \left(\left| \frac{\text{MMP}_{\text{Predicted}} - \text{MMP}_{\text{Experimental}}}{\text{MMP}_{\text{Experimental}}} \right| \times 100 \right) \quad (4)$$

Kao što je uobičajeno, raspoložive grupe eksperimentalnih podataka podijeljene su u dvije grupe. Oko 25 grupa podataka je odvojeno kako bi se koristilo za ispitivanje integriteta mreže i otpornost na manja odstupanja nakon uvježbavanja. Preostali podatci su korišteni kod uvježbavanje mreže za nepoznati vektor težine. Kada je vektor težine izračunat, najvažniji preostali zadatak je utvrditi kako dobro radi mreža nakon svršetka uvježbavanja. Kontrola rada uvježbane mreže uključuje sljedeće glavne kriterije:

1. Koliko dobro neuralna mreža priziva izlazni vektor iz grupe podataka korištenih za uvježbavanje mreže.

2. Koliko dobro neuralna mreža predviđa odzive za grupe podataka ispitivanja korištene za uvježbavanje.

Za usporedbu rezultata mreže s rezultatima klasične linearne korelacije (regresije), kao što je to napravljeno u

Tablica 1. Rezultati neuralne mreže i pogreška procjene

	ARE	AARE	Koeficijent korelacije (<i>R</i>)
Podatci uvježbavanja	0,162 614	2,433 171	0,994 987
Podatci provjere	-0,071 18	6,613 956	0,954 987

Tablica 2. Rezultati korelacije i pogreška procjene

Korelacija		ARE	AARE	Koeficijent korelacije (<i>R</i>)
Alston et al.	Podatci uvježb.	3,737 107 8	22,977 177	0,767 814
	Podatci provjere	-12,005 88	20,252 608	0,917 055
Glaso	Podatci uvježb.	-112,208 9	112,259 27	0,664 883
	Podatci provjere	-99,988 42	100,335 12	0,861 566
Yuan et al.	Podatci uvježb.	-50,791 8	55,326 692	0,341 611
	Podatci provjere	-30,980 48	38,531 976	0,730 303

primjeru^{1,9,21} dizajnirana su i programirana grafička korisnička sučelja (GUI - graphical user interface) korištenjem funkcije MATLAB.

4. Rezultati i diskusija

Rezultati ANN u simulaciji podataka uvježbavanja i provjere prikazani su u Tablici 1 i Sl. 2 i 3. Rezultati izračunavanja MMP korelacijom prikazani su u Tablici 2.

Kao što je pokazano u tablicama 1 i 2, model ANN za MMP daje bolji rezultat (*ARE*, *AARE*, *R*) od korelacija korištenih u ovom radu. ANN model dao je 6,61 za *AARE* i 0,96 za faktor korelacije, a kod statističke korelacije *AARE* je 53,03.

Usporedbom rezultata korelacije i prijašnjih istraživanja MMP korištenjem Neuralne mreže, rezultati su u ovom radu prihvatljivi.^{17,13}

5. OPĆI ZAKLJUČCI

Iz ovog rada izvučeni su sljedeći zaključci:

- Model je razvijen za predviđanje CO₂ MMP pomoću umjetne neuronske mreže.
- Utvrđena je stupnjevita procedura za modeliranje mreže.
- CO₂ MMP su programirani korištenjem MATLAB, kako bi se lagano usporedili njihovi rezultati s ANN rezultatima.
- Prosječna relativna apsolutna pogreška za podatke provjere dobivena korištenjem ANN je 6,61, a za korelacije prosječno 53,03.
- Usporedbom rezultata ANN modela i korelacija, dokazano je da se inteligentne regresijske metode, kao što je ANN, mogu u naftnoj industriji koristiti za predviđanje složenih pojava, kao što je tlak miscibilnosti koji zavisi o nekoliko čimbenika i mehanizama, bolje od rutinskih metoda statističke regresije.

6. Zahvala

Autori se zahvaljuju svojem rukovoditelju Dr. M. Jamialahmadiu za njegovo vođenje i poticanje na provedbi ovog projekta.



Autori:

Abolfazl Bagheri Nezhad, Department of Chemical Engineering and Petroleum, Sharif University of Technology, Tehran, Iran

S. Maryam Mousavi, Department of Energy Engineering, Sharif University of Technology, Tehran, Iran

Sepehr Aghahoseini, Department of Petroleum Engineering, Islamic Azad University, Kharg, Iran

UDK : 553.982 : 622.24.63.5 : 622.276/.279 : 53.08

553.982 ležišta nafte i plina
622.24.63.5 rudarstvo, iscrpljivanje ležišta
622.276/.279 pridobivanje nafte
53.08 mjerenja (MMPANN,RBF)