

Voorspelling van die prestasie van 'n op-die-plaas-tipe direkteuitsetting-grootmaatmelkverkoeler met behulp van kunsmatige neurale netwerke

R Mhundwa, M Simon

Universiteit van Fort Hare, Suid-Afrika

Korresponderende outeur: R Mhundwa E-pos: rmhundwa@gmail.com

Die prestasie van 'n op-die-plaas-tipe direkteuitsetting-grootmaatmelkverkoeler ("DXBMC" na aanleiding van die bekende Engelse benaming waarmee daarna verwys word) is voorspel deur die gebruik van kunsmatige neurale netwerkmodelle. Data is op 'n bestaande plaas ingesamel gedurende die tydperk April 2016–Maart 2017. Die data is in MATLAB opgelaa om kunsmatige neurale netwerke (KNN'e) te ontwikkel en die energieverbruik en die prestasiekoëffisiënt (PK) van die DXBMC te simuleer. Die data is 70:15:15 verdeel, wat onderskeidelik opleidings-, validerings- en toetsdatastelle verteenwoordig. Twee KNN'e is vir die energieverbruik en die PK onderskeidelik ontwikkel. Verskeie neurale netwerke is geskep en in 'n sistematiese prosedure opgelei. Seleksie van die beste kombinasie van voorspellers vir die modelle is gebaseer op die bepaaldheidskoëffisiënt (R), wortel van gemiddelde kwadraatfout (WGKF) en gemiddelde absolute persentasiefout (GAPF). Die belangrikheid van die insette vir die uitset is ook afgelei. Die resultate het hoë akkuraatheid in voorspellings van die energieverbruik en die PK getoon, aangesien die waardes van die GAPF minder as 5% was. Daar is gevind dat die R^2 waardes vir die voorspelling van die elektriese energieverbruik en PK onderskeidelik 0,9459 en 0,9999964 is. Deur 'n sensitiwiteitsanalise het dit geblyk dat die volume melk die belangrikste faktor is wat die energieverbruik van 'n op-die-plaas-tipe DXBMC sowel as die PK daarvan beïnvloed. Die toepassing van KNN-modelle vir die voorspelling van die prestasie van 'n grootmaatmelkverkoeler is nuttig vir melkplase, aangesien hulle deeglike energiebestuur en strategieë benodig vir die doeltreffende werking van 'n melkverkoelingstelsel, want dit is een van die belangrikste bedrywighede en verbruik baie energie.

Sleutelwoorde: Direkteuitsetting-grootmaatmelkverkoeler; kunsmatige neurale netwerk; prestasiekoëffisiënt; suiwelmelkverkoeling; kragverbruik

Prediction of the performance of an on-farm direct expansion bulk milk cooler using artificial neural networks: The performance of an on-farm direct expansion bulk milk cooler (DXBMC) is predicted through the use of artificial neural network models. Data was collected at an existing farm for the period of April 2016–March 2017. The data were submitted to MATLAB to develop artificial neural networks (ANNs) and simulate the energy consumption and coefficient of performance (COP) of the DXBMC. The data was split 70:15:15, representing training, validation and testing datasets respectively. Two ANNs were developed for the energy consumption and COP respectively. Several neural networks were created and trained in a systematic procedure. Selection of the best combination of predictors for the models was based on the coefficient of determination (R), root mean square error (RMSE) and mean absolute percentage error (MAPE). The importance of the inputs to the output were also deduced. The results showed high precision in predictions for both energy consumption and COP, as the values of the MAPE were less than 5%. The R^2 values for predicting the electrical energy consumption and COP were found to be 0,9459 and 0,9999964, respectively. Through a sensitivity analysis, the volume of milk proved to be the most important factor influencing energy consumption of the on-farm DXBMC as well as its COP. The application of ANN models for predicting the performance of a bulk milk cooler is useful for dairy farms as they require thorough energy management and strategies for the efficient operation of a milk cooling system since it is one of the major operations that consumes much energy.

Keywords: Direct expansion bulk milk cooler; artificial neural network; coefficient of performance; dairy milk cooling; energy consumption

Inleiding


Die gebruik van kunsmatige-intelligensiestelsels (KI-stelsels) en masjienleertegniese in die verkoelingsveld het oor die jare toegeneem om 'n paar komplekse probleme op te los, soos gerapporteer deur Mohanraj *et al.* (2012). Die KI-stelsels sluit in KNN, vae logika en 'n ineen-smelting van baie stelsels, wat twee of meer tegnieke kombineer (Kalogirou, 2003; Mellit & Kalogirou, 2008; Mohanraj *et al.*, 2012). KNN is vinnige en eenvoudige modelle wat probleme van 'n komplekse aard kan oplos wat betref onderlinge verwantskappe tussen veranderlikes deur die nielineêre verwantskappe tussen veranderlikes te verkry. Hulle is biologies geïnspireerde berekeningsmodelle, is al gebruik om ingewikkelde nielineêre onderlinge verwantskappe tussen 'n menigte faktore uit te beeld, en hulle boots ook die breinfunksie na op 'n gerekenariseerde manier, gebaseer op die transmissie en ontvangs van seine (Agatonovic-Kustrin & Beresford, 2000; Kalogirou, 2003; Mellit & Kalogirou, 2008; Mohanraj *et al.*, 2012). Figuur 1 bied 'n illustrasie van 'n kunsmatige neuron.

KNN word gebou uit onderling verbinde neurone wat inligting van die insette af na die verlangde uitsette verwerk. Die generering van die uitset vanuit die insette word gefasiliteer deur verbindingsgewig, wat die insette aan die sommeringsfunksie en aan die oordragfunksie koppel. Gebaseer op die literatuur, is verskillende KNN-argitekture soos multilaag-vorentoevoernetwerke (MLVNN), veralgemeenderegressie- neurale netwerke (VRNN), adaptiewe neurovaekoppelvlakstelsels (ANVKS) en radiaalsydigefunksienetwerke (RBFN), onder andere (Jang, 1993; Kalogirou, 2003; Mellit & Kalogirou, 2008; Mohanraj *et al.*, 2012) op verkoelingstelsels toegepas. Oor die jare is navorsing gedoen oor 'n verskeidenheid verkoelingstelsels wat verskillende benaderings en KNN-modelargitekture gebruik. Ertunc en Hosoz (2006) het 'n studie gedoen oor 'n kaskadeverkoelingstelsel waar MLVNN toegepas is om die prestasie daarvan te voorspel. Die eksperimentele resultate is noukeurig deur die KNN-model nageboots. 'n Ondersoek deur Redy *et al.* (2020) het gefokus op die gebruik van meervoudige regressieanalise (MRA) en KNN om die prestasie van 'n huishoudelike yskas te voorspel. Die studie het tot die gevolgtrekking gekom dat prestasievoorspelling met gebruik van die KNN-model baie akkuraat was. In 'n ander studie het Opalic *et al.* (2020) 'n KNN-

gebaseerde tegniek ontwikkel vir die modellering van die werking van 'n verkoelingstelsel wat CO₂ as 'n koelmiddel in 'n industriële opset gebruik. Ribault *et al.* (2019) het 'n KNN gebruik om temperatuur te voorspel vir 'n koelkamer waar 'n dinamiese programmeringsalgoritme gebruik is. Gill en Singh (2018) het ook dimensielose korrelasie- en KNN-modelle ontwikkel om die massavloeiempo in 'n dampkompressie-verkoelingstelsel te voorspel. In verskeie ander studies is KNN's wyd op verskeie verkoelingstelsels gebruik om energieverbruik (kragverbruik), verkoelingskapasiteit en prestasiekoëffisiënt te voorspel (Swider *et al.*, 2001; Ertunc & Hosoz, 2006; Navarro-Esbri *et al.*, 2007; Escobedo-Trujillo *et al.*, 2016; Barroso-Maldonado *et al.*, 2017; Aprea *et al.*, 2017). Talle tegnieke vir prestasievoorspelling van dampkompressieverkoelingstelsels gebaseer op simulaties en modellering is deur Ding (2007) aangebied.

Studies oor die toepassing van masjienleer is ook op suiwelplase gedoen. Shine *et al.* (2018) het 'n studie aangebied waar 'n reeks masjienleeralgoritmes toegepas is op die voorspelling van elektrisiteit en direkte waterverbruik op die plaas op weiding-gebaseerde kommersiële lense suiwelplase. Sefeedpari *et al.* (2014) het 'n adaptiewe neurale inferensiestelsel geïmplementeer om uitsetenergie te modelleer, gebaseer op energieë uit fossielbrandstowwe en elektrisiteit insette vir melkplase in Iran. Dit is die moeite werd om te noem dat die akkuraatheid van modelprestasie nuttig is om energieverbruik in 'n suiwelonderneming te voorspel. Dit vorm die basis vir verbeterde energiedoeltreffendheid-beplanningstrategieë vir die verbeterde bedryf van 'n plaas. Gebaseer op die hersiene literatuur het KNN-modelle bewys dat hulle hoë akkuraatheid het in die voorspelling van die prestasie van verkoelingstelsels. Na die skrywer se wete word die toepassing van KNN op grootmaatmelkverkoelers egter slegs in 'n beperkte mate in literatuur gedek.

Die hoofdoel van die huidige studie is om KNN-modelle te ontwikkel vir die voorspelling van die prestasie van 'n op-die-plaas-tipe DXBMC. Toepassing van die ontwikkelde KNN'e op die verkoelingsenergievereistes op 'n melkplaas sal insig gee in die verkoelingsprestasie van die DXBMC. Hierdie insig sal voorsiening maak vir optimalisering van die verkoelingstelsel,



Figuur 1: Kunsmatige neuron aangepas van Kalogirou (2003), en Mellit en Kalogirou (2008)

prestasiEVERBETERING, onderhoudskedulering asook energiebesparings waar melktemperatuur op die beste moontlike minimum gehou moet word. Deur die ontwikkelde KNN-model te gebruik, word die prestasie van die DXBMC wat betref energieverbruik en PK tydens die daaglikse melkskema van 'n suiwelplaas bepaal.

Materiale en Metodes

Data-insameling

Data is vir die tydperk April 2016–Maart 2017 by 'n bestaande plaas ingesamel volgens die prosedures wat deur Mhundwa *et al.* (2017) uiteengesit is. 'n Melkroetine van twee maal per dag is deur die jaar waargeneem, dit wil sê vroegoggend (05:00–07:00) en laatmiddag (15:00–17:00). Die skematiese uitleg van die eksperimentele prosedure word in Figuur 2 getoon.

Teorie en berekening

Die termiese hitte wat deur die DXBMC uit die melk verwyder word, word in Vergelyking 1 bereken:

Vergelyking 1

$$Q = \frac{mC_{pm}(T_{mi} - T_{mf})}{3600} \quad (1)$$

Waar

m = massa melk gelewer aan die grootmaatmelkverkoeler (kg)

C_{pm} = spesifieke hittekapasiteit van melk (3,93 kJ/kg °C)

T_{mi} = melkinlaattemperatuur gelewer aan die DXBMC

T_{mf} = finale melktemperatuur in die DXBMC (4 °C)

Vergelyking 2 toon die PK-berekening vir die DXBMC:

Vergelyking 2

$$COP = \frac{E}{Q} \quad (2)$$

Waar

E = gemete energieverbruik vir die DXBMC (kWh)


Formulering en opleiding van die KNN'e

Die versamelde data vir 'n jaar (April 2016–Maart 2017) is by MATLAB ingedien om kunsmatige KNN's te ontwikkel en die energieverbruik en PK van die DXBMC te simuleer. Die data is 70:15:15 verdeel, wat onderskeidelik opleidings-, validerings- en toetsdatastelle verteenwoordig. Twee KNN-modelle is ontwikkel, naamlik vir die energieverbruik en vir die PK onderskeidelik. Vir hierdie studie is 'n MLVVN toegepas wat met die Levenberg Marquardt-algoritme (LM-algoritme) opgelei is. Verskeie neurale netwerke is volgens 'n sistematiese prosedure geskep en opgelei. Die basiese neurale netwerke word in Figuur 2 weer-gegee. Die basiese struktuur van die argitektuur van 'n KNN-netwerk word in drie lae geskei, naamlik die inset-, die versteekte en die uitsetlaag (Figuur 2). Die insetlaag het uit die inset-veranderlikes bestaan, wat in hierdie studie die melkvolume (V_{milk}), melktemperatuur (T_{milk}), omgewingstemperatuur (T_{amb}), kamertemperatuur (T_{room}) en relatiewe humiditeit (RH) was, wat vir die elektriese-energie-KNN in aanmerking geneem is (KNN_{E}), terwyl energieverbruik, V_{milk} , T_{milk} , T_{amb} , T_{room} en RH vir die PK-KNN (KNN_{PK}) gebruik is. Tabel I toon die besonderhede van die ontwikkelde KNN'e.

Om die beste kombinasie van insetparameters te evalueer om die energieverbruik en die PK van die DXBMC te voorspel, is die voorwaartse stapsgewyse regressie-seleksiemetode toegepas. In hierdie metode word al die veranderlikes as insette in die KNN geneem om die beste kombinasie van veranderlikes te bepaal vir die voorspelling van die energieverbruik en die PK onderskeidelik. Die keuse van die beste kombinasie is gebaseer op R, WGKF en GAPF. Figuur 3 illustreer die neurale netwerkargitektuur vir energieverbruik en die PK van 'n DXBMC.

Simulasie, validering en foutanalise

Prestasie van die netwerk is met behulp van R getoets, terwyl die betroubaarheid van die model deur die GAPF bepaal is en die vergelyking tussen die gemete en voorspelde waardes deur die WGKF afgelei is. Die volgende vergelykings wys hoe R, GAPF en WGKF bereken word:



Figuur 2: Eksperimentele uitleg van die DXBMC a) kondenseringseenheid, b) kamertemperatuursensor, c) grootmaatmelkverkoeler, d) melktemperatuursensor, e) kragmeter, f) datavasleggers, g) relatiewe humiditeit- en omgewingstemperatuursensor (Bron: Mhundwa *et al.*, 2018)

$$R = \frac{\sum_{i=1}^n (M_i - \bar{M})(P_i - \bar{P})}{\sqrt{\sum_{i=1}^n (M_i - \bar{M})^2} \times \sqrt{\sum_{i=1}^n (P_i - \bar{P})^2}} \quad (3)$$

$$MAPE = \frac{\sum_{i=1}^n \left| \frac{M_i - P_i}{M_i} \right|}{n} \quad (4)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (M_i - P_i)^2} \quad (5)$$

Waar vir vergelykings 1, 2 en 3:

M = gemete waarde

P = voorspelde waarde

n = getal van data

Elke voorspeller vir die bes presterende KNN-model is getoets om die bruikbaarheid daarvan in die voorspelling van die uitsette (energieverbruik en PK) te bepaal. Dit is gedoen deur een voorspeller op 'n slag te verwyder en die toename en afname in die GAPF, WGKF en R na te gaan.

Rangorde van voorspellers se belangrikheid ten opsigte van uitset

Die verbindingsgewigbenadering is gebruik om die model-insette te rangorden volgens hul effek op die uitset. Volgens Olden en Jackson (2002) en Olden *et al.*, (2004), bepaal die verbindingsgewigmetode die relatiewe belangrikheid van voorspellers van 'n KNN-model as 'n funksie van die neurale-

netwerk-gewigte. Hierdie metode is gekies op grond van die akkuraatheid daarvan, aangesien dit afgelei is van die gewigte van die KNN (De Oña & Garrido, 2014).

Metings- en berekeningsonsekerheid

Eksperimentele data en afgeleide berekeninge word bepaal deur die akkuraatheid van die instrumente wat gebruik word om die data in te samel (Coleman & Steele, 2018). In hierdie studie het metings van temperatuur, relatiewe humiditeit, omgewingstemperatuur en krag onderskeidelik toleransies van $\pm 0,15^\circ\text{C}$, $\pm 2,5\%$, $\pm 0,21^\circ\text{C}$ en 1% gehad (Mhundwa *et al.*, 2018).


Resultate en Bespreking

Die prestasie van 'n DXBMC wat betref energieverbruik en PK kan voorspel word met gebruik van die KNN-model met die insetparameters wat in Figuur 1 getoon word. Die getal neurone wat vir hierdie studie in aanmerking geneem is, was tussen twee en 12 vir beide die voorspelling van die energieverbruik sowel as die PK, en die netwerk is verskeie kere opgelei ten einde die fout tussen die voorspelde waardes te minimaliseer. Tabel II toon 'n korrelasiematriks vir die veranderlikes.

Die korrelasiekoëffisiënte wat in Tabel II aangebied word, is van Pearson se metode afgelei. Daar kan waargeneem word dat die meeste van die korrelasiekoëffisiënte laag is, behalwe vir Troom en Tamb (0,960), Troom en RH (−0,829) en Tamb en RH (−0,877). Dit is as gevolg van die inverse en direkte wisselwerking tussen die verskillende weer veranderlikes. Daar moet kennis geneem word dat hoë korrelasies tussen veranderlikes tot die oormatige passing van 'n model kan lei.

Tabel I: Opsomming van die ontwikkelde KNN'e

KNN _E -beskrywing			KNN _{PK} -beskrywing
Struktuur	Insette	Aantal neurone	
		1. Melktemperatuur	1. Melktemperatuur
		2. Melkvolume	2. Melkvolume
		3. Kamertemperatuur	3. Kamertemperatuur
		4. Relatiewe humiditeit	4. Relatiewe humiditeit
		5. Omgewingstemperatuur	5. Omgewingstemperatuur
		6. Energieverbruik	
	Versteekte laag	Aantal neurone = 2–12	
	Uitset	Aantal neurone = 1 (kragverbruik)	Aantal neurone = 1 (PK)
Oordragfunksie	Versteekte neurone	Tangenssigmoïed	
	Uitset neurone	Suiwer lineêr	
Opleiding metode		Opleidingsdoelwitte: minimum gemiddelde vierkante fout	
		Tydperk: 1 000 keer	
		Algoritme: Levenberg Marquardt	
Databasisgrootte		180	180
Databasis-partisionering		Opleiding: 70%	
		Validering: 15%	
		Toets: 15%	



Figuur 3: Neurale netwerkgitektuur vir energieverbruik en die PK

Tabel II: Korrelasiematriks vir die veranderlikes

Veranderlikes	Vmilk	Tamb	RH	Tmi	Troom
Vmilk	1				
Tamb	-0,497	1			
RH	0,395	-0,877	1		
Tmi	0,041	0,410	-0,491	1	
Troom	-0,472	0,960	-0,829	0,445	1

KNN-modelle

KNN-modelle is ontwikkel met alle voorspellers, en Tabel III en Tabel IV illustreer die prestasieaanwysers.

Soos aangedui in Tabel III, maak Vmilk die grootste deel van die voorspellende inligting vir energieverbruik uit. Dit is as gevolg van die hoë korrelasie (0,84) daarvan met energieverbruik. Daar kan waargeneem word dat die byvoeging van Tmilk as een van die voorspellers tot verbeterde prestasie van die KNN-model gelei het. Met 12 neurone het die WGKF en GAPF onderskeidelik met 43,56% en 44,15% afgeneem, terwyl R met 9% toegeneem het. Verdere byvoeging van Troom by die voorspellers het die WGKF met 'n verdere 13% en GAPF met 7% verminder, terwyl R van 0,9636 tot 0,9725 toegeneem het. Deur Tamb as een van die

Tabel III: KNN_E-modelle

Model	Voorspellers	NN	WGKF (kWh)	GAPF (%)	R
1	Vmilk+Tmilk+Troom+Tamb+RH	6	5,6496	4,1621	0,9726
2	Vmilk+Tmilk+Troom+Tamb	8	6,0752	4,2886	0,9679
3	Vmilk+Tmilk+Troom	8	5,6319	4,1473	0,9725
4	Vmilk+Tmilk	12	6,4736	4,4465	0,9636
5	Vmilk	8	11,4689	7,9619	0,8805


Tabel IV: KNN_{COP}-modelle

Model	Voorspellers	NN	WGKF	GAPF (%)	R
1	Energieverbruik+Vmilk+Tmilk+Troom+Tamb+RH	12	0,00037208	0,00919173	0,9999982
2	Energieverbruik+Vmilk+Tmilk+Troom+Tamb	10	0,00057565	0,0076484	0,99999573
3	Energieverbruik+Vmilk+Tmilk+Troom	12	0,00031892	0,00953144	0,99999867
4	Energieverbruik+Vmilk+Tmilk	8	0,00025759	0,00838367	0,99999916
5	Energieverbruik+Vmilk	10	0,04999166	1,65165818	0,96706873
6	Energieverbruik	10	0,1812502	6,3688037	0,37563743


voorspellers by te voeg, is verminderde prestasie merkbaar, met 'n toename in WGKF tot 6,075 kWh sowel as 'n effense verlaging in R tot 0,9679. Dit was die gevolg van die interaksie-effek tussen die Tamb en Troom as gevolg van die ligging van die DXBMC, soos berig in Mhundwa *et al.* (2017), asook die oortolligheid wat veroorsaak is deur die hoë korrelasiekoëffisiënt tussen die twee veranderlikes wat in Tabel III getoon word. Byvoeging van RH het R effens tot 0,9726 verhoog, en het WGKF en GAPF onderskeidelik met 7% en 3% verminder. Die prestasie van KNN-model 1 (Tabel III) dui daarop dat al vyf die insetveranderlikes tot beter prestasie wat betref R (0,9726) gelei het. Die prestasie van model 1 en model 3 is nou verwant wat betref R. Die WGKF en GAPF is egter effens laer vir model 3.

Die afleiding van die resultate in Tabel IV is dat die gebruik van al die voorspellers in die model tot 'n beter prestasie van die netwerk lei. Die verwydering van RH as een van die voorspellers verminder R met minder as 0,00025%, met 'n toename in WGKF


en 'n afname in GAPF. Die prestasie van die netwerk ná verwydering van Tamb is sodanig dat R en GAPF toeneem het, terwyl WGKF afgeneem het. 'n Netwerk met energieverbruik, Vmilk en Tmilk toon die beste prestasie met die hoogste R (0,99999916) en die laagste WGKF (0,00025759). Energieverbruik en Vmilk bevat die meeste van die voorspellende inligting vir die PK van 'n DXBMC. Daar kan afgelei word dat die toevoeging van Vmilk as een van die voorspellers gelei het tot verbeterde prestasie van die KNN-model. Die WGKF en GAPF het onderskeidelik met 72,42% en 74,07% gedaal, terwyl R met 157,45% toeneem het. Verdere byvoeging van Tmilk by die voorspellers het die WGKF met 'n verdere 99,48% verminder en GAPF met 99,49%, en R het van 0,96706873 tot 0,99999916 toeneem. Boonop, deur Troom as 'n voorspeller by te voeg, is verminderde prestasie merkbaar met 'n toename in WGKF ook, en 'n effense vermindering in R. Figuur 4 en Figuur 5 illustreer die KNN-voorspelde energieverbruik, en die werklike energieverbruik en PK vir 'n DXBMC.




Figuur 4: KNN-voorspelde energieverbruik en werklike energieverbruik vir 'n DXBMC



Figuur 5: KNN-voorspelde energieverbruik en werklike PK vir 'n DXBMC



Figuur 6: KNN_E-regressiestippings



Figuur 7: KNN_{PK}-regressiestippings



Vergelyking van die eksperimentele steekproefdata en KNN-voorspellingsresultate vir energieverbruik en PK word in Figuur 4 en 5 getoon. Die stippings gee 'n visuele voorstelling van die voorspellingsfoute. Die vergelykings toon dat die KNN'e die eksperimentele data betekenisvol verteenwoordig het; dus bevestig die resultate die merkwaardige vermoë van die KNN-modelle om energieverbruik en PK te voorspel. Figuur 6 en 7 illustreer die regressiestippings vir die KNN_E en KNN_{PK}.

Die vier stippings in Figuur 6 en Figuur 7 verteenwoordig die regressiestippings vir opleiding, validering, toetsing en al die data vir die energieverbruik en PK, onderskeidelik. Die perfekte resultaat van uitsette = mikpunte word deur die swart stippellyn voorgestel, terwyl die aaneenlopende lyne die beste aangepaste lineêre regressie tussen uitsette en mikpunte verteenwoordig (Figuur 6 en Figuur 7). Die mikpunt- en uitsetdata wat deur die kunsmatige neurale netwerk gegenereer word, vorm die ooreenstemmende horisontale en vertikale as. Daar kan afgelei word dat die opleidingsdata 'n goeie passing het met $R = 0,97989$, wat beteken dat die uitsetdata van die KNN die verlangde mikpuntdata nageboots het. Die resultate toon ook dat die R -waardes vir die validerings- en toetsdata groter as 0,95 was. Net so kan daar uit Figuur 6 afgelei word dat die opleidingsdata op 'n goeie passing dui, met $R = 0,99999$. Die validerings- en toetsresultate het ook R -waardes bo 0,99 opgelewer. Die resultaat het aangedui dat die energieverbruik

en PK van 'n DXBMC suksesvol met hoë akkuraatheid deur 'n enkellaag-KNN voorspel is. Figuur 8 en 9 toon die valideringsprestasie van die KNN'e wat ontwikkel is.

Die skepping van die KNN'e se struktuur wat in die modellering van die energieverbruik PK gebruik, is onderskeidelik op 10 tydstippe en 12 tydstippe uitgevoer. Die beste valideringsooreenstemming by gemiddelde kwadraatfout (GKF) = 34,5666 is by die 10e tydstip bereik, waar $R^2 = 0,9759$, terwyl $GKF = 1,851 \times 10^{-6}$ by die 12e tydstip bereik is, by $R^2 = 0,9999964$ vir die PK. Figuur 8 en 9 illustreer ook die praktiese uitvoerbaarheid van die opleidingsresultate vir die KNN'e. Dit word gesien in die weglaatbaar klein foute tussen die opleidings- en die valideringsdatastelle. Opmerklik is dat hierdie foute nie betekenisvol verander het met verdere opleiding van die KNN'e nie. Figuur 10 en 11 illustreer die fouthistogram vir KNN_E en KNN_{PK}.

Die KNN_E- en KNN_{PK}-modelfoute is afgelei van die verskil tussen die voorspelde waardes en die werklike waardes. In daardie opsig dui die positiewe foute aan dat die voorspelde waarde vir die KNN die werklike waarde onderskat het, terwyl negatiewe foute aandui dat die voorspelde waarde die werklike waarde te hoog geraam het. Deur Figuur 10 en 11 te ontleed, kan ons waarneem dat die meerderheid van die foute langs die nulfoutlyn geleë is. Die voorspelling wat deur die opgeleide KNN gelewer is, is dus heel aanvaarbaar.


Figuur 8: KNN_E-valideringsprestasiëFiguur 9: KNN_{PK}-valideringsprestasië

Relatiewe belangrikheid van die voorspellers


Die indeks van relatiewe belangrikheid (R_i) is vir elk van die voorspellers afgelei vir die bepaling van die verhouding van die voorspeller tot die respons, soos geïllustreer in Figuur 12 en 13.

Soos aangedui in Figuur 12, het Vmilk, Tmilk en Troom in die positiewe rigting afgewyk, terwyl RH en Tamb in die negatiewe rigting afgewyk het, teen byna dieselfde grootte. Dit impliseer dat Vmilk, Tmilk en Troom 'n positiewe verhouding met energieverbruik gehad het. Gevolglik het Vmilk die mees


beduidende bydrae tot energieverbruik ($R_i = 1,902$), gevolg deur Troom ($R_i = 1,378$). Die resultate toon dat die energieverbruik van die DXBMC meer sensitief was vir die verandering in Vmilk. Volgens Figuur 13 is energieverbruik die mees deurslaggewende veranderlike in die voorspelling van die PK van 'n DXBMC ($R_i = -5,817$), gevolg deur Vmilk ($R_i = 3,350$) en Tmilk ($R_i = 1,284$). Troom, Tamb en RH het die kleinste tot die PK van die stelsel bygedra. Die PK van die DXBMC was sensitiefste vir die verandering in die energieverbruik, gevolg deur Vmilk en Tmilk. Verder moet genoem word dat die PK die minste sensitief was vir Troom, Tamb en RH. Die bevindinge van hierdie studie dui




Figuur 10: Foutverspreiding vir KNN_E



Figuur 11: Foutverspreiding vir KNN_{PK}



Figuur 12: Relatiewe belangrikheid van voorspellers vir KNN_E



Figuur 13: Relatiewe belangrikheid van voorspellers vir KNN_{PK}

daarop dat Vmilk en Tmilk beduidende voorspellers is vir die prestasie van 'n DXBMC. Dus sal optimalisering van Vmilk en Tmilk bydra tot die doeltreffende werking van die DXBMC. Rou melk verlaat meestal die koei by 'n temperatuur van 35–37 °C en maak vinnige afkoeling tot 'n temperatuur van 4 °C dit veilig (Lewis en Heppell, 2000; Holm *et al.*, 2004; Upton *et al.*, 2010). Dit dui daarop dat in 'n direkte melk-tot-verkoelingstelsel, melk teen ongeveer 32 °C aan die DXBMC gelewer word (Mhundwa *et al.*, 2018); dus sal energieverbruik ook toeneem. Daarteenoor het vorige studies (Peebles *et al.*, 1993; O'Keeffe, 2007; Murphy *et al.*, 2013; Mhundwa *et al.*, 2016) aan die lig gebring dat voorafverkoeling van melk met grondwater as koelmiddel die temperatuur van die melk tot gemiddeld 19,9 °C kan verlaag. Hierdie studies het getoon dat daar 'n afname van 50,3% in energieverbruik was, en dat die gebruik van 'n roumelk-voorverkoeler die doeltreffendheid van die DXBMC verhoog het, wat gelei het tot 'n aansienlike vermindering in energieverbruik. Intuïtief kan Tmilk doeltreffend op 'n melkplaas beheer word. Kuddegrootte en seleksie van beesrasse, plaasgrootte en kwaliteit van voer kan egter op hul beurt 'n impak hê op die volume melk (Vmilk) wat geproduseer word (Dillon *et al.*, 2003; Franzoi *et al.*, 2020).

Ten slotte

Die prestasie van 'n op-die-plaas-tipe DXBMC is ontleed in 'n poging om energieverbruik en prestasiekoëffisiënt te voorspel deur modelle wat gebaseer is op KNN'e wat opgelei is met 'n databasis verkry uit data wat op 'n bestaande melkplaas gemeet is. Die bevindinge van die studie word soos volg opgesom:

1. Die resultaat het aangedui dat die energieverbruik en PK van 'n DXBMC deur 'n enkellaag- neurale netwerk voorspel kan word
2. Die akkuraatheid wat deur die KNN-modelle opgelewer word, is aanvaarbaar en kan gebruik word vir op die plaas-tipe DXBMC'e om die melkverkoelingsbedrywighede te monitor en te optimeer.
3. Die indeks van relatiewe belangrikheid van die voorspellers toon dat Vmilk en Tmilk die noodsaaklikste veranderlikes is vir die voorspelling van beide die energieverbruik en die PK van 'n DXBMC.
4. Die energieverbruik is meestal sensitief vir die Vmilk, terwyl die PK meestal sensitief is vir energieverbruik.

Erkennings

Die finansiële ondersteuning van die Universiteit van Fort Hare deur die Govan Mbeki-navorsingsentrum word met dank erken.

Datums

Ontvang: 28/04/2023

Aanvaar: 11/04/2024

Gepubliseer: 15/07/2024

Bibliografie

- Agatonovic-Kustrin, S., Beresford, R., 2000, Basic concepts of artificial neural network (ANN) modelling and its application in pharmaceutical research, *Journal of Pharmaceutical and Biomedical Analysis* 22(5), 717-727. [https://doi.org/10.1016/S0731-7085\(99\)00272-1](https://doi.org/10.1016/S0731-7085(99)00272-1).
- Aprea, C., Greco, A., Maiorino, A., 2017, An application of the artificial neural network to optimise the energy performances of a magnetic refrigerator, *International Journal of Refrigeration* 82, 238-251. <https://doi.org/10.1016/j.jirefrig.2017.06.015>.
- Barroso-Maldonado, J.M., Belman-Flores, J.M., Ledesma, S., et al., 2017, Predicting the energy performance of a reciprocating compressor using artificial neural networks and probabilistic neural networks, *Revista Mexicana de Ingeniería Química* 16(2), 679-690.
- Belman-Flores, J.M., Mota-Babiloni, A., Ledesma, S. et al., 2017, Using ANNs to approach to the energy performance for a small refrigeration system working with R134a and two alternative lower GWP mixtures, *Applied Thermal Engineering* 127, 996-1004. <https://doi.org/10.1016/j.applthermaleng.2017.08.108>.
- Chan, S.Y., Chau, C.K., 2019, Development of artificial neural network models for predicting thermal comfort evaluation in urban parks in summer and winter, *Building and Environment* 164, 106364. <https://doi.org/10.1016/j.buildenv.2019.106364>.
- Chang, Y.-C., 2007, Sequencing of chillers by estimating chiller power consumption using artificial neural networks, *Building and Environment* 42, 180-188. <https://doi.org/10.1016/j.buildenv.2005.08.033>.
- Coleman, H.W., Steele, W.G., 2018, Experimentation, validation, and uncertainty analysis for engineers. John Wiley & Sons. <https://doi.org/10.1002/9781119417989>.
- De Oña, J., Garrido, C., 2014, Extracting the contribution of independent variables in neural network models: a new approach to handle instability, *Neural Computing and Applications* 25, 859-869. <https://doi.org/10.1007/s00521-014-1573-5>.
- Dillon, P., Snijders, S., Buckley, F., et al., 2003, A comparison of different dairy cow breeds on a seasonal grass-based system of milk production: 2. Reproduction and survival, *Livestock Production Science* 83(1), 35-42. [https://doi.org/10.1016/S0301-6226\(03\)00042-3](https://doi.org/10.1016/S0301-6226(03)00042-3).
- Ding, G.L., 2007, Recent developments in simulation techniques for vapour-compression refrigeration systems, *International Journal of Refrigeration* 30(7), 1119-1133. <https://doi.org/10.1016/j.jirefrig.2007.02.001>.
- Elhami, B., Khanali, M., Akram, A., 2017, Combined application of Artificial Neural Networks and life cycle assessment in lentil farming in Iran, *Inf Process Agric* 4, 18e32. <https://doi.org/10.1016/j.inpa.2016.10.004>.
- Ertunc, H.M., Hosoz, M., 2006, Artificial neural network analysis of a refrigeration system with an evaporative condenser, *Applied Thermal Engineering* 26(5-6), 627-635. <https://doi.org/10.1016/j.applthermaleng.2005.06.002>.
- Escobedo-Trujillo, B.A., Colorado, D., Rivera, W., et al., 2016, Neural network and polynomial model to improve the coefficient of performance prediction for solar intermittent refrigeration system, *Solar Energy* 129, 28-37. <https://doi.org/10.1016/j.solener.2016.01.041>.
- Franzoi, M., Manuelian, C.L., Penasa, M., et al., 2020, Effects of somatic cell score on milk yield and mid-infrared predicted composition and technological traits of Brown Swiss, Holstein Friesian, and Simmental cattle breeds, *Journal of Dairy Science* 103(1), 791-804. <https://doi.org/10.3168/jds.2019-16916>.
- Gill, J., Singh, J., 2018, Use of artificial neural network approach for depicting mass flow rate of R134a/LPG refrigerant through straight and helical coiled adiabatic capillary tubes of vapor compression refrigeration system, *International Journal of Refrigeration* 86, 228-238. <https://doi.org/10.1016/j.jirefrig.2017.11.001>.
- Halkjær, S., Winther, O., 1997, The effect of correlated input data on the dynamics of learning, In *Advances in Neural Information Processing Systems*, 169-175.
- Holm, C., Jepsen, L., Larsen, M., et al., 2004, Predominant microflora of downgraded Danish bulk tank milk, *J Dairy Sci* 87, 1151-57. [https://doi.org/10.3168/jds.S0022-0302\(04\)73263-4](https://doi.org/10.3168/jds.S0022-0302(04)73263-4).
- Hosoz, M.H., Ertunc, M., 2006, Modeling of a cascade refrigeration system using artificial neural networks, *International Journal of Energy Research* 30, 1200-15. <https://doi.org/10.1002/er.1218>.
- Jang, J.-S.R., 1993, ANFIS: adaptive-network-based fuzzy inference system, *IEEE Transactions on Systems, Man and Cybernetics* 23, 665-685. <https://doi.org/10.1109/21.256541>.
- Kalogirou, S.A., 2003, Artificial intelligence for the modeling and control of combustion processes: a review, *Progress in Energy and Combustion Science* 29(6), 515-566. [https://doi.org/10.1016/S0360-1285\(03\)00058-3](https://doi.org/10.1016/S0360-1285(03)00058-3).
- Lewis, M.J., Heppell, N., Hastings, A., 2000, Continuous thermal processing of foods-Pasteurisation and UHT Sterilisation, Aspen Publishers, Inc., Gaithersburg.
- Mellit, A., Kalogirou, S.A., 2008, Artificial intelligence techniques for photovoltaic applications: A review, *Progress in Energy and Combustion Science* 34(5), 574-632. <https://doi.org/10.1016/j.peecs.2008.01.001>.
- Mhundwa, R., Simon, M., Tangwe, S., 2017, Comparative analysis of the coefficient of performance of an on-farm direct expansion bulk milk cooler, In *Proceedings of the International Conference on Industrial and Commercial Use of Energy (ICUE)*, Stellenbosch University 15-17 August 2017. <https://doi.org/10.23919/ICUE.2017.8067998>.
- Mhundwa, R., Simon, M., Tangwe, S.L., 2018, Modelling of an on-farm direct expansion bulk milk cooler to establish baseline energy consumption without milk pre-cooling: A case of Fort Hare Dairy Trust, South Africa, *African Journal of Science, Technology, Innovation and Development* 10(1), 62-68. <https://doi.org/10.1080/20421338.2017.1385132>.
- Mohanraj, M., Jayaraj, S., Muraleedharan, C., 2012, Applications of artificial neural networks for refrigeration, air-conditioning and heat pump systems-a review, *Renewable and Sustainable Energy Reviews* 16(2), 1340-1358. <https://doi.org/10.1016/j.rser.2011.10.015>.
- Murphy, M., Upton, J., O'Mahony, M., 2013, Rapid milk cooling control with varying water and energy consumption, *Bio Engineering* 116, 15-22. <https://doi.org/10.1016/j.biosystemseng.2013.05.007>.
- Navarro-Esbrí, J., Berbegall, V., Verdub, G., et al., 2007, A low data requirement model of a variable-speed vapour compression refrigeration system based on neural networks, *International Journal of Refrigeration* 30, 1452-1459. <https://doi.org/10.1016/j.jirefrig.2007.03.007>.
- O'Keeffe J., 2007, Milk Cooling, Inservice Training Teagasc, Moorepark Research Centre http://www.teagasc.ie/advisory/farm_management/buildings/milkingEquipment/milk_cooling/MilkCoolingPresentation.pdf.
- Olden J.D., Jackson D.A., 2002, Illuminating the "black-box": a randomization approach for understanding variable contributions in artificial neural networks, *Ecological Modelling* 154, 135-150. [https://doi.org/10.1016/S0304-3800\(02\)00064-9](https://doi.org/10.1016/S0304-3800(02)00064-9).
- Olden, J.D., Joy, M.K., Death, R.G., 2004, An accurate comparison of methods for quantifying variable importance in artificial neural networks using simulated data, *Ecological Modelling* 178(3-4), 389-397. <https://doi.org/10.1016/j.ecolmodel.2004.03.013>.
- Opalic, S.M., Goodwin, M., Jiao, L., et al., 2020, ANN modelling of CO2 refrigerant cooling system COP in a smart warehouse, *Journal of Cleaner Production* 260, 120887. <https://doi.org/10.1016/j.jclepro.2020.120887>.
- Peebles, R., Reinemann, D., Straub, R., 1993, Analysis of milking center energy use, Presented at the 1993 Winter Meeting of the ASAE, Chicago, Illinois, ASAE.
- Piñeiro, G., Perelman, S., Guerschman, J.P., et al., 2008, How to evaluate models: observed vs. predicted or predicted vs. observed? *Ecological Modelling* 216(3-4), 316-322. <https://doi.org/10.1016/j.ecolmodel.2008.05.006>.
- Pires dos Santos, R., Dean, D.L., Weaver, J.M.Y., et al., 2019, Identifying the relative importance of predictive variables in artificial neural networks based on data produced through a discrete event simulation of a manufacturing environment, *International Journal of Modelling and Simulation* 39(4), 234-245. <https://doi.org/10.1080/02286203.2018.1558736>.
- Reddy, D.R., Bhramara, P., Govindarajulu, K., 2020, A comparative study of multiple regression and artificial neural network models for a domestic refrigeration system with a hydrocarbon refrigerant mixtures, *Materials Today: Proceedings* 22, 1545-1553. <https://doi.org/10.1016/j.matpr.2020.02.116>.
- Ribault, A., Vercraene, S., Henry, S., et al., 2019, Economically optimal control of a cold room using an artificial neural network and dynamic programming, *IFAC-PapersOnLine* 52(13), 2002-2007. <https://doi.org/10.1016/j.ifacol.2019.11.497>.
- Saidur, R., Masjuki H.H., Jamiludhin M.Y., 2006, A new method to investigate the energy performance of a household refrigerator-freezer, *International Energy Journal* 7, 9-15.
- Sefeedpari, P., Rafiee, S., Akram, A., et al., 2014, Modeling output energy based on fossil fuels and electricity energy consumption on dairy farms of Iran: Application of adaptive neural-fuzzy inference system technique, *Computers and Electronics in Agriculture* 109, 80-85. <https://doi.org/10.1016/j.compag.2014.09.010>.
- Shine, P., Murphy, M.D., Upton, J., et al., 2018, Machine-learning algorithms for predicting on-farm direct water and electricity consumption on pasture based dairy farms, *Computers and Electronics in Agriculture* 150, 74-87. <https://doi.org/10.1016/j.compag.2018.03.023>.
- Swider, D.J., Browne, M.W., Bansal, P.K., 2001, Modelling of vapour-compression liquid chillers with neural networks, *Applied Thermal Engineering* 21(3), 311-329. [https://doi.org/10.1016/S1359-4311\(00\)00036-3](https://doi.org/10.1016/S1359-4311(00)00036-3).
- Upton, J., Murphy, M., French, P., et al., 2010, Energy consumption in dairy farms. In *Proceedings of the national dairy conference Mullingar Teagasc*, 87-97.
- Yilmaz, S., Atik K., 2007, Modeling of a mechanical cooling system with variable cooling capacity by using artificial neural network, *Applied Thermal Engineering* 27, 2308-13. <https://doi.org/10.1016/j.applthermaleng.2007.01.030>.