



รายงานการวิจัย

การประยุกต์ใช้ Neural Networks สำหรับการค้นหาค่าความเข้มข้นสำคัญ
ของสารละลาย β - Glucan

Applying Neural Networks for Rapid Assessment of Critical
Concentration of β - Glucan Suspensions

คณะผู้วิจัย

หัวหน้าโครงการ

นางรัชฎาพร อุ่นศิริไธย์

สาขาวิชาเทคโนโลยีอาหาร

สำนักวิชาเทคโนโลยีเกษตร

ผู้ร่วมวิจัย

1. ดร.ชยันท์ อุ่นศิริไธย์

2. นางวิษุตา มงคล

ได้รับทุนอุดหนุนการวิจัยจากมหาวิทยาลัยเทคโนโลยีสุรนารี ปีงบประมาณ 2544

ผลงานวิจัยเป็นความรับผิดชอบของหัวหน้าโครงการวิจัยแต่เพียงผู้เดียว

กรกฎาคม 2547

กิตติกรรมประกาศ

การวิจัยครั้งนี้ได้รับทุนอุดหนุนการวิจัยจากมหาวิทยาลัยเทคโนโลยีสุรนารี ปีงบประมาณ 2544 และผู้วิจัยขอกราบขอบพระคุณบิดามารดา ที่ให้การอบรมและส่งเสริมเป็นอย่างดี และที่สำคัญขอขอบคุณครอบครัวของผู้วิจัยสำหรับการสนับสนุนและกำลังใจอันดี จนทำให้ผู้วิจัยประสบความสำเร็จในชีวิต

บทคัดย่อภาษาไทย

เทคนิคทางสถิติเป็นเครื่องมือมาตรฐานที่ใช้กันอย่างเหมาะสมสำหรับการพัฒนา model ที่มีพื้นฐานเกี่ยวกับอิทธิพลระหว่างตัวแปรจากการทดลอง เมื่อเร็วๆ นี้ neural networks (NNs) ได้มีการนำมาประยุกต์ใช้อย่างกว้างขวางในการแก้ปัญหาในหลายสาขาวิชา รวมทั้งสาขาวิชาเทคโนโลยีอาหาร NNs ได้มีการพัฒนาแนวความคิดมาจากการศึกษาการทำงานของระบบสมองและระบบประสาท และมีความเชื่อมั่นว่าให้ผลอย่างน้อยเท่ากับหรือดีกว่าเทคนิคต้นแบบทางสถิติแบบสามัญ ถ้าความสัมพันธ์ของข้อมูลไม่ได้เป็นเส้นตรง (non-linear)

จากการนำ NNs มาประยุกต์ใช้กับการหาค่าความเข้มข้นสำคัญ (C^*) ของชุดข้อมูล ความสัมพันธ์ระหว่าง $1/\text{Log relative viscosity}$ และความเข้มข้นของสารละลาย $\beta\text{-glucan}$ ในสภาวะ 7 ระบบ buffer พบว่าสามารถวิเคราะห์หาค่าความเข้มข้นสำคัญ (C^*) ของสารละลาย $\beta\text{-glucan}$ ในสภาวะ 7 ระบบ buffer ได้โดยมีค่า correlation ที่ดีขึ้น

บทคัดย่อภาษาอังกฤษ

Statistics analysis is the standard tool for model development based on reaction between variables from experiments. Neural network (NNs) has been applied to solving problem in many disciplines including food technology. NNs developed idea from study of how brain and neural system work. In addition, it was believed that the results were good or better than basic statistics technique if the relationship was non linear.

NNs was applied for determine the critical concentration (C^*) of β -glucan concentration in 7 buffer systems. The results showed that there were better correlations from using new data set.

สารบัญ

หน้า

กิตติกรรมประกาศ	ก
บทคัดย่อภาษาไทย	ข
บทคัดย่อภาษาอังกฤษ	ค
สารบัญ	ง
สารบัญตาราง	จ
สารบัญภาพ	ฉ
บทที่ 1 บทนำ	
ความสำคัญและที่มาของปัญหาการวิจัย	1
วัตถุประสงค์ของการวิจัย	2
ขอบเขตของการวิจัย	2
ประโยชน์ที่ได้รับจากการวิจัย	2
บทที่ 2 วิธีดำเนินการวิจัย	
แหล่งที่มาของข้อมูล	3
ระเบียบวิธีวิจัย.....	3
วิธีการเก็บรวบรวมข้อมูล	3
วิธีวิเคราะห์ข้อมูล	4
บทที่ 3 ผลการวิเคราะห์ข้อมูล	
อภิปรายผล	13
บทที่ 4 บทสรุป	
สรุปผลการวิจัย	15
บรรณานุกรม	16
ประวัติผู้วิจัย	17

สารบัญตาราง

	หน้า
ตารางที่ 1	12

สารบัญภาพ

	หน้า
รูปที่ 1	4
รูปที่ 2a	5
รูปที่ 2b	5
รูปที่ 3a	6
รูปที่ 3b	6
รูปที่ 4a	7
รูปที่ 4b	7
รูปที่ 5a	8
รูปที่ 5b	8
รูปที่ 6a	9
รูปที่ 6b	9
รูปที่ 7a	10
รูปที่ 7b	10
รูปที่ 8a	11
รูปที่ 8b	11

บทที่ 1

บทนำ

ความสำคัญและที่มาของปัญหาการวิจัย

เทคนิคทางสถิติเป็นเครื่องมือมาตรฐานที่ใช้กันอย่างเหมาะสมสำหรับการพัฒนา model ที่มีพื้นฐานเกี่ยวกับอัตรากิริยาระหว่างตัวแปรจากการทดลอง เมื่อเร็ว ๆ นี้ neural networks (NNs) ได้มีการนำมาประยุกต์ใช้อย่างกว้างขวางในการแก้ปัญหาในหลายสาขาวิชา รวมทั้งสาขาวิชาเทคโนโลยีอาหาร NNs ได้มีการพัฒนาแนวความคิดมาจากการศึกษาการทำงานของระบบสมองและระบบประสาท และมีความเชื่อมั่นว่าให้ผลอย่างน้อยเท่ากับหรือดีกว่าเทคนิคต้นแบบทางสถิติแบบพหุสมการ ถ้าความสัมพันธ์ของข้อมูลไม่ได้เป็นเส้นตรง (non-linear)

NNs มีความทนต่อสิ่งแวดลอมในข้อมูลจริง นอกจากนี้ NNs ไม่ต้องการการเลือกของข้อมูลอิสระที่สำคัญที่สุดในการเซทข้อมูล หรือฟอร์มเกี่ยวกับหน้าที่ของต้นแบบความสามารถของ NNs ที่จะเรียนรู้จากตัวอย่างหรือข้อมูลในอดีตทำให้ NNs มีความยืดหยุ่นและเป็นเครื่องมือที่มีพลังความสามารถในการจัดต้นแบบของระบบที่ซับซ้อน โดยปราศจากความเข้าใจเกี่ยวกับกลไกที่เป็นมูลฐาน ในปัจจุบันนี้มีผู้นำโปรแกรมสำเร็จรูปของ NNs มาใช้อย่างแพร่หลายในการประยุกต์ต้นแบบ และมี NNs หลายประเภทให้เลือกซึ่งขึ้นอยู่กับความซับซ้อนของปัญหา เมื่อข้อมูลได้รับการฝึกฝน (trained) NNs สามารถนำมาใช้ในการทำนายหรือคาดการณ์ล่วงหน้า (prediction) อย่างมีประสิทธิภาพ

รัชฎาพร (2543) ได้ศึกษาเกี่ยวกับการหาจุดเข้มข้นที่สำคัญของสารละลาย β - glucan จากหลักการที่ว่า ความเข้มข้นสำคัญ (C^*) คูณด้วย Intrinsic viscosity ($C[\eta]$) จะเท่ากับ 1.0 ถึง 10.0 ที่ระดับความเข้มข้นสำคัญกึ่งละลาย (semidilute regime) (Kasaai et al., 2000) พบว่าค่า Intrinsic viscosity จากการใช้ Martin equation , Kozicki and Kuang Method (1999), Lincman and Kruger Method (1996) , Kramer equation ที่แตกต่างกันซึ่งเกี่ยวข้องกับค่าความเข้มข้นที่แตกต่างกันด้วย Jindal และ Hombual (2000) ได้นำ neural networks มาใช้ในการประเมินคุณภาพทางด้านจุลชีววิทยาของนมดิบ และพบว่าสามารถนำ neural network models มาใช้ในการประมาณ methylene blue reduction time ของตัวอย่างนมดิบ จากการวัดคุณสมบัติทางกายภาพและเคมีของนม

วัตถุประสงค์ของการวิจัย

เพื่อพัฒนาเทคนิคเกี่ยวกับการนำ NNs ไปใช้ในการทำนายจุดเข้มข้นสำคัญ (Critical concentration) ของสารละลาย β - glucan ที่ซึ่ง β - glucan เริ่มที่รวมตัวกันที่จะพันกัน (entangle) ซึ่งเป็นจุดเริ่มต้นที่จะนำไปสู่การสร้าง gel ของสารละลาย β - glucan

ขอบเขตของการวิจัย

การวิจัยนี้เน้นศึกษาการนำ NNs มาประยุกต์ใช้ในการพัฒนาต้นแบบของการหาความเข้มข้นที่สำคัญของสารละลาย β - glucan

ประโยชน์ที่ได้รับจากการวิจัย

1. ได้ข้อมูลเกี่ยวกับวิธีการค้นหาจุดเข้มข้นสำคัญ (Critical concentration) โดยไม่ใช้วิธีการทางสถิติ
2. สามารถนำวิธีการที่ได้ไปประยุกต์ใช้ในการค้นหาจุดเข้มข้นสำคัญ (Critical concentration) ของสารละลายที่มีพฤติกรรมมีการเปลี่ยนแปลงความหนืด (viscosity) แบบ polymer

บทที่ 2

วิธีดำเนินการวิจัย

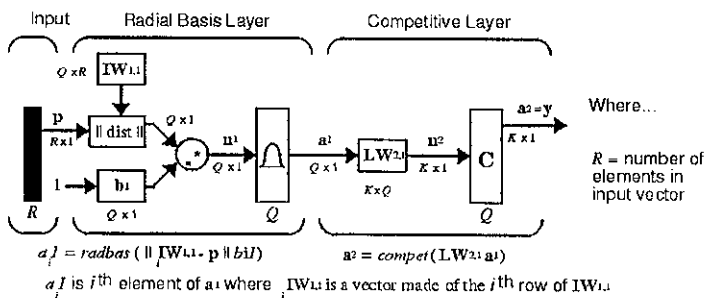
แหล่งที่มาของข้อมูล

ได้นำข้อมูลจากการศึกษาหาจุดเข้มข้นสำคัญของสารละลาย β - glucan โดยรัชฎาพร (2543) ซึ่งประกอบด้วยข้อมูลเกี่ยวกับความสัมพันธ์ระหว่าง ค่า $1/\text{Log relative viscosity}$ และ ค่าความเข้มข้นของสารละลาย β - glucan (0.1-1.0 g/dL) จากการทดลอง 7 สภาวะการทดลอง (High ethanol, Low ethanol, Control, High maltose, Low maltose, High pH, Low pH)

ระเบียบวิธีวิจัย

การศึกษาระบบ neural network modeling

Neural networks แบบ probabilistic สามารถนำมาใช้ได้กับปัญหาที่เฉพาะ เมื่อมีการใส่ข้อมูลเข้าไป ระดับชั้นแรก(first layer)คำนวณระยะทางจาก input vector ไปยัง input vector ที่กำลังฝึกหัดอยู่ และสร้าง vector ที่มีลักษณะระบุว่า input ใกล้เคียงกับ (training input ใดๆ ระดับชั้นที่สองจะรวมผลสำหรับแต่ละกลุ่มของข้อมูลเพื่อที่จะสร้าง net output vector ของความน่าจะเป็น สุดท้าย compete transfer function บนข้อมูลในระดับชั้นที่สอง(second layer) เลือกความน่าจะเป็นที่สูงที่สุด และสร้าง 1 สำหรับ class นั้น และสร้าง 0 สำหรับ class อื่น ๆ การออกแบบระบบนี้แสดงดังรูปที่ 1.



Q = number of input/target pairs = number of neurons in layer 1
 K = number of classes of input data = number of neurons in layer 2

รูปที่ 1 Neural networks แบบ probabilistic. (taken from Alexandra and Morton, 1990)

จากรูปที่ 1 มีคู่ของ Q input vector หรือ target vector แต่ละ target vector ประกอบด้วย ส่วนประกอบ 7 ส่วน ส่วนหนึ่งของส่วนประกอบนี้ คือ 1 และส่วนประกอบที่เหลือคือ 0 ดังนั้นแต่ละ input vector มีความสัมพันธ์กับ K class หนึ่งตัว น้ำหนักของ input ในระดับชั้นแรกคือ $IW_{1,1}$ (net.IW{1,1}) ถูกกำหนดให้แปล รูปแบบของ Matrix จาก คู่อันดับ Q คือ P

เมื่อมี input ปรากฏ dist box สร้าง vector ที่มีส่วนประกอบซึ่งระบุความใกล้เคียงของ input กับ training set elements เหล่านี้ถูกคูณไปที่ละ element โดย bias และส่ง หน่วยเคลื่อนย้าย redbas input vector ที่ใกล้เคียงกับ vector ที่กำลังฝึกหัดถูกนำเสนอโดยตัวเลขที่ใกล้เคียงเลข 1 ใน output vector a1 ถ้า input ใกล้เคียงกับ vector ฝึกหัดหลายตัวใน class เดียวกัน จะถูกนำเสนอโดย element หลายตัวของ a1 ซึ่งใกล้เคียงกับ 1


น้ำหนักของ input ในระดับชั้นสองคือ $LW_{1,2}$ (net.LW{2,1}) ถูกกำหนดเป็น Matrix T ของ target vector แต่ละ vector มี 1 เฉพาะในแถวที่สัมพันธ์กับ class จำเพาะของ input และมี 0 ในตำแหน่งอื่น ๆ การคูณ Ta_1 รวมพื้นฐานของ a จากแต่ละ class ของ k input ในที่สุด ชั้นที่ 2 ซึ่งทำหน้าที่เป็นหน่วยเคลื่อนย้าย กำหนด 1 สำหรับจำนวนที่มากที่สุดของ n2 และกำหนด 0 สำหรับตำแหน่งอื่น ๆ ดังนั้นเครือข่ายสามารถแจกแจง vector ที่ให้เข้ามา ในหน่วยจำเพาะของ class K เพราะว่า Class นั้นมีความน่าจะเป็นเกี่ยวกับความถูกต้องมากที่สุด

วิธีวิเคราะห์ข้อมูล


จากการประยุกต์ใช้ NNs นำข้อมูลความสัมพันธ์ระหว่างค่า $1/\log$ relative viscosity และ ค่าความเข้มข้นของสารละลาย β - glucan (0.1-1.0 g/dL) จากการทดลอง 7 สภาวะการทดลอง (High ethanol, Low ethanol, Control, High maltose, Low maltose, High pH, Low pH) ที่ได้จากการประยุกต์ใช้ neural network model มาใช้ในการหาค่าความเข้มข้นสำคัญ (C^*) โดยใช้ piecewise regression เทคนิคของโปรแกรม SystatTM 5.05 Windows (SPSS Inc., Evanston, IL)

การเปรียบเทียบข้อมูลที่ได้จากการประยุกต์ใช้ neural network model ของความสัมพันธ์ระหว่างค่า $1/\log$ relative viscosity และ ค่าความเข้มข้นของสารละลาย β - glucan แสดงดังรูปที่ 2a


ถึงรูปที่ 8b



รูปที่ 2a. ความสัมพันธ์ระหว่าง $1/\log$ relative viscosity กับ ความเข้มข้นของสารละลาย β -glucan ใน high ethanol buffer (รัชฎาพร, 2543).




รูปที่ 2b. ความสัมพันธ์ระหว่าง $1/\log$ relative viscosity กับ ความเข้มข้นของสารละลาย β -glucan ใน high ethanol buffer จากการใช้ neural network model .




รูปที่ 3a. ความสัมพันธ์ระหว่าง $1/\log$ relative viscosity กับ ความเข้มข้นของสารละลาย

β -glucan ใน low ethanol buffer (วิษณุพร, 2543).




รูปที่ 3b. ความสัมพันธ์ระหว่าง $1/\log$ relative viscosity กับ ความเข้มข้นของสารละลาย

β -glucan ใน low ethanol buffer จากการใช้นิวรัลเน็ตเวิร์กโมเดล .




รูปที่ 4a. ความสัมพันธ์ระหว่าง 1/log relative viscosity กับ ความเข้มข้นของสารละลาย

β -glucan ใน control buffer (รัชฎาพร, 2543).




รูปที่ 4b. ความสัมพันธ์ระหว่าง 1/log relative viscosity กับ ความเข้มข้นของสารละลาย

β -glucan ใน control buffer จากการใช้นิวรัลเน็ตเวิร์กโมเดล .




รูปที่ 5a. ความสัมพันธ์ระหว่าง 1/log relative viscosity กับ ความเข้มข้นของสารละลาย

β -glucan ใน high maltose buffer (รัชฎาพร, 2543).




รูปที่ 5b. ความสัมพันธ์ระหว่าง 1/log relative viscosity กับ ความเข้มข้นของสารละลาย

β -glucan ใน high maltose buffer จากการใช้นิรล network model .




รูปที่ 6a. ความสัมพันธ์ระหว่าง 1/log relative viscosity กับ ความเข้มข้นของสารละลาย

β -glucan ใน low maltose buffer (รัชฎาพร, 2543).




รูปที่ 6b. ความสัมพันธ์ระหว่าง 1/log relative viscosity กับ ความเข้มข้นของสารละลาย

β -glucan ใน low maltose buffer จากการใช้ neural network model .




รูปที่ 7a. ความสัมพันธ์ระหว่าง 1/log relative viscosity กับ ความเข้มข้นของสารละลาย

β -glucan ใน low pH buffer (รัชฎาพร, 2543).




รูปที่ 7b. ความสัมพันธ์ระหว่าง 1/log relative viscosity กับ ความเข้มข้นของสารละลาย

β -glucan ใน low pH buffer จากการใช้นeural network model .



รูปที่ 8a. ความสัมพันธ์ระหว่าง 1/log relative viscosity กับ ความเข้มข้นของสารละลาย

β -glucan ใน high pH buffer (รัชฎาพร, 2543).



รูปที่ 8b. ความสัมพันธ์ระหว่าง 1/log relative viscosity กับ ความเข้มข้นของสารละลาย

β -glucan ใน low pH buffer จากการใช้ neural network model .

ตารางที่ 1. การเปรียบเทียบค่าความเข้มข้นวิกฤติจากข้อมูลเดิมและจากข้อมูลที่ได้จากการประยุกต์ใช้ neural network model

Buffer condition	β -glucan concentration (mg/ml)	C*(old) (mg/ml)	C*(new)/10 (mg/ml)	r ² (old)	r ² (new)
High ethanol	1.00	0.6465	0.64479167	0.968	0.96695
Low ethanol	2.00	0.2721	0.26659924	0.942	0.9757
Control	3.00	0.3192	0.32540354	0.912	0.9562
High maltose	4.00	0.2134	0.24972431	0.924	0.96925
Low maltose	5.00	0.305	0.31118774	0.911	0.95945
Low pH	6.00	0.3945	0.40107849	0.965	0.98305
High pH	7.00	0.305	0.31503509	0.904	0.96825

บทที่ 3

ผลการวิเคราะห์ข้อมูล

อภิปรายผล

ในทางปฏิบัติในห้องปฏิบัติการ การหาค่าความเข้มข้นวิกฤติ (C^*) เป็นการทดลองที่ต้องใช้ เวลาในการทดสอบและไม่สามารถแปรผันค่าความเข้มข้นของสารละลายได้ใกล้เคียงกันมากเพื่อที่จะ ได้ข้อมูลในแต่ละจุดที่ละเอียด หนึ่งเนื่องจากปัญหาการเตรียมสารละลายที่มีพฤติกรรมคล้าย โพลีเมอร์ที่ ่การเปลี่ยนแปลงคุณสมบัติทางวิทยากระแสมือเวลาหรือสภาวะแวดล้อมเปลี่ยนแปลงตลอดเวลา ึ่งนั้นการนำ neural network model มาประยุกต์ใช้เพื่อสร้างข้อมูลเพิ่มซึ่งไม่สามารถทำได้ทาง ้องปฏิบัติการจึงเป็นประโยชน์ในการวิเคราะห์ข้อมูลทางสถิติ

จากการวิจัยนี้ได้มีการนำเทคนิคของ Probabilistic Neural Network Classifier (PNN) มาใช้ใน การทำนายจุดเข้มข้นสำคัญ (C^*) ของสารละลาย β -glucan โดย PNN ใช้ตัวประมาณค่าของ Parzen Probabilistic density functions (pdfs) ซึ่งใช้ผลรวมของ spherical Gaussian functions centre ของแต่ละ training vector เพื่อใช้ในการประมาณค่าของ classes pdfs นอกจากนี้ PNN สามารถใช้กลยุทธ์ของ Bayes สำหรับ decision rules และทำให้มีความน่าจะเป็นและการวัดค่าที่เชื่อถือได้ การฝึกหัดกระทำ โดยคัดเลือก factor รานเรียบเดี่ยวที่เหมาะสมซึ่งเป็น ค่าเบี่ยงเบนมาตรฐานสามัญสำหรับ Gaussian ทุก ตัว network จะมีความทนต่อการเกิด error จากการ training vector และทำให้ data sample ที่เบาบาง มี ค่าที่เหมาะสม (Zanich, 1997)

ฟังก์ชัน spherical Gaussian radial basis คือ การประมาณค่า Parzen pdfs และถูกใช้ใน PNN ดัง สมการต่อไปนี้

$$f_i(x) = \frac{1}{(2\pi)^{p/2} \sigma^p M_i} \sum_{j=1}^{M_i} \exp \frac{-(x - x_{ij})^T (x - x_{ij})}{2\sigma^2} \quad (1)$$

เมื่อ:

T : transpose

i : class number

j : pattern number

x_{ij} : j th training vectors ใน class i

x : test vector

M_i : number ของ training vectors ใน class i

S : total number ของ training vectors ($\sum_i M_i$)

P : input vector dimension

σ : smoothing vector หรือ bandwidth

$f_i(x)$: ผลรวมของ multivariate spherical Gaussians centred ของแต่ละ training vector x_{ij} ,
สำหรับ i , class pdf estimate

C_i : class I เมื่อ $I = 1, 2, 3, \dots, N$.

N : number ของ class

จากการนำ neural network model มาประยุกต์ใช้กับข้อมูลความสัมพันธ์ของ $1/\log$ relative viscosity กับ ความเข้มข้นของสารละลาย β -glucan ทำให้ได้ชุดข้อมูลที่มีความละเอียดมากขึ้นและแสดงถึงความเที่ยงตรงของชุดข้อมูล ดังรูปที่ 1b, 2b, 3b, 4b, 5b, 6b, 7b ซึ่งมีผลเมื่อนำข้อมูลชุดใหม่มาใช้ในการหาค่าความเข้มข้นวิกฤต (C^*) ทำให้สามารถได้ค่า C^* ที่มีค่า correlation ที่สูงกว่าชุดข้อมูลเดิมที่ไม่ได้ประยุกต์ใช้ neural network model ดังแสดงในตารางที่ 1

บทที่ 4

บทสรุป

จากการนำ neural net work model โดยใช้ระบบ PNN มาประยุกต์ใช้เพื่อให้ได้ชุดข้อมูลใหม่ในการวิเคราะห์หาค่าความเข้มข้นวิกฤติ (C^*) ทำให้ได้ค่า C^* ที่ใกล้เคียงกับค่า C^* เดิมแต่มีค่า correlation ที่สูงกว่าเดิม ซึ่งจากผลการวิจัยนี้ สามารถนำไปประยุกต์ใช้ในการหาค่าความเข้มข้นวิกฤติของสารละลายที่มีพฤติกรรมคล้ายโพลิเมอร์และมีความยุ่งยากในการแปรผันค่าความเข้มข้นที่ใกล้เคียงกันในทางปฏิบัติในห้องปฏิบัติการ ซึ่งผู้ทดลองที่ต้องการหาค่า C^* สามารถออกแบบการทดลองโดยแปรผันค่าความเข้มข้นที่สามารถทำได้และหาค่าความหนืดของสารละลายแต่ละความเข้มข้นเพื่อให้ได้ชุดข้อมูลดิบก่อน แล้วจึงนำ PNN มาใช้ในการประมาณค่าความหนืดของสารละลายที่ระดับความเข้มข้นที่ไม่สามารถทำได้ในห้องทดลองเพื่อให้ได้ชุดข้อมูลใหม่ที่มีความละเอียดมากขึ้น แล้วจึงนำชุดข้อมูลใหม่มาค่า C^* โดยใช้วิธีการทางสถิติ

นอกจากนี้ยังสามารถประยุกต์ใช้ neural network models โดยใช้ PNN ในการหาค่าความสัมพันธ์ของค่าความหนืด (viscosity) หรือคุณสมบัติทางวิทยากระแสนอื่น ๆ ในกรณีที่ต้องใช้ nonlinear regression model ซึ่งจะช่วยให้สามารถวิเคราะห์ข้อมูลได้ละเอียดมากขึ้นและนำมาซึ่งผลการวิเคราะห์ทางสถิติที่ดี

โดยสรุปแล้ว neural network models โดยใช้ PNN เป็น models มีความเที่ยงตรงในกรณีที่มีชุดข้อมูลเบาบางและมีประโยชน์มากในด้านการวิเคราะห์ข้อมูลโดยเฉพาะสามารถนำไปประยุกต์ใช้ในด้านการศึกษาคุณสมบัติทางด้านกายภาพของอาหารหรือสารละลายเข้มข้นที่เปลี่ยนแปลงได้ง่ายในสภาวะแวดล้อมต่าง ๆ ได้แก่ อุณหภูมิ pH เป็นต้น

บรรณานุกรม

- Alexsandra, J. and H. Morton. 1990. An introduction to Neural Computing. Chapman and Hall, London.
- Andal, V.K. and Homhual, S. 2000. Applying neural networks for rapid assessment of microbiological quality of bulk raw milk. Engineering Journal Kasetsart. ฉบับที่ 41 ปีที่ 14 สิงหาคม-พฤศจิกายน 2543. ISBN 0857-4154 P.69-86.
- Oonsivilai, R. 2000. The effect of β -glucan polymers on the rheological and filtration properties of wort. MSc. Thesis. Dalhousie University-Daltech, Halifax, NS. Canada.
- Oonsivilai, R., Speers, R.A. and Paulson, A.T. 2000. Effects of pH, maltose and ethanol on the physical properties of model beta-glucan suspensions. Presented at IOB 2000, Institute of Brewing, Asia-Pacific Section 26th Convention, Mar. 19-24, Singapore, SGP.
- Oonsivilai, R. Patelakis, S.J.J., Speers, R.A., and Paulson, A.T. 1999. Rheological and filtration properties of beta-glucan polymers in the brewing process. CIIST Annual Meeting, Presentation #OR-12, June 6-9, Kelowna, BC.
- U. Alex Speers, S. J. J. Patelakis, and R. Oonsivilai. 2004. Shear rates in brewing operations. MBAA. In process.
- Sanich, A. 1997. A vector Quantisation reduction method for the probabilistic neural network. IEEE. Vol. 8. pp. 1117-1120

CURRICULUM VITAE

Name: **Mrs. RATCHADAPORN OONSIVILAI**
Date of birth: September, 1965
Nationality: Thai
Marital status: Married
Health: Excellent

Address: 111 University Avenue
Mueng District
Nakhon Ratchasima
Thailand 30000

PROFESSIONAL EDUCATION:

1997–2000 : Master of Science (Food Science)
Dalhousie University DalTech
1360 Barrington Street
Sexton Campus
P.O Box 1000
Halifax, Nova Scotia
Canada B3J 2X4

Thesis topic: **“The Effect of β -Glucan Polymers on the Rheological and Filtration Properties of Wort”**

1983-1987: Bachelor of Science (Nursing)
Faculty of Nursing
Khonkaen University, Thailand

Independent study topic: “Study on population’s knowledge in Rubella”

WORK EXPERIENCE:

Oct.1999 - Present : Lecturer, Department of Food Technology
Institute of Agricultural Technology
Suranaree university
Nakhon Ratchasima, Thailand

Sept.1997 –Oct.1999: Research Assistant
Department of Food Science and Technology
Dalhousie University DalTech
Halifax, Nova Scotia, Canada

Oct. 1993-Aug.1997 : Register Nurse
University Infirmary
Suranaree University of Technology
Nakhon Ratchasima Thailand

May.1987- Sept.1993: Register Nurse
Intensive care unit, Srinakarin hospital
Khonkaen University
Khonkaen, Thailand

PUBLICATION:

1. THESIS

Topic: **“The Effect of β -Glucan Polymers on the Rheological and Filtration Properties of Wort”**

- Research task: - Estimate shear rate in various unit operations in the brewery.
- Determine the intrinsic viscosity of 327 kDa β -glucan as a function of pH, maltose and ethanol.
- Determine the effect of molecular weight on the intrinsic viscosity of the β -glucan.
- Determine C^* as a function of pH, maltose and ethanol in seven buffer system.
- Determine the effect of pH, maltose and ethanol on buffer filterability.

2. PRESENTED PAPERS AND POSTER AT CONFERENCE

- 2.1 Oonsivilai, R., Speers, R.A. and Paulson, A.T. 2000. Effects of pH, maltose and ethanol on the physical properties of model beta-glucan suspensions. Presented at IOB 2000, Institute of Brewing, Asia-Pacific Section 26th Convention, Mar. 19-24, Singapore, SGP.
- 2.2 Oonsivilai, R. Patelakis, S.J.J., Speers, R.A., and Paulson, A.T. 1999. Rheological and filtration properties of beta-glucan polymers in the brewing process. CIFST Annual Meeting, Presentation #OR-12, June 6-9, Kelowna, BC.
- 2.3 Speers, R. A., Patelakis, S.J.J., and Oonsivilai, R. 2000. Shear rate in brewing operation. In proceed.

SKILLS/EXTRA CURRICULAR ACTIVITIES:

- Rheometer machine (Bohlin, VOR)
- Capillary Electrophoresis

REFERENCES:

Prof. Tom Gill
Food Science and Technology Department
Dalhousie University DalTech
1360 Barrington Street
Sexton Campus
P.O Box 1000
Halifax, Nova Scotia.
Canada B3J 2X4

Prof. Alex Speers
Food Science and Technology Department
Dalhousie University DalTech
1360 Barrington Street
Sexton Campus
P.O Box 1000
Halifax, Nova Scotia
Canada B3J 2X4