

# การทำนายความแข็งแรงดึงของเหล็กหล่อเหนียวด้วยปัญญาประดิษฐ์

## Prediction of Ultimate Tensile Strength of Ductile Iron by Artificial Intelligence

วิชชуда ธงกิ่ง

Witchuda Thongking

คณะวิศวกรรมศาสตร์ มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าธนบุรี กรุงเทพฯ ประเทศไทย  
Faculty of Engineering, King Mongkut's University of Technology Thonburi, Bangkok, Thailand

รชยา สินธุสิงห์, ธาริกา พันธุ์เลิศ, ยุทธนา น้อยเมือง, อุษณีย์ กิตกัธรร,  
ภูษิต มิตรสมหวัง, รัตน์ บิริสุทธิกุล\*

Rotchaya Sinthusing, Dharika Phanlert, Yutthana Noimueang,

Usanee Kitkumthorn, Pusit Mitsomwang, Rattana Borrisutthekul\*

สำนักวิชาวิศวกรรมศาสตร์ มหาวิทยาลัยเทคโนโลยีสุรนารี จ.นครราชสีมา ประเทศไทย  
Institute of Engineering, Suranaree University of Technology,

Nakhon-Ratchasima, Thailand

\*Corresponding author E-mail: rattana@g.sut.ac.th

Received 4 October 2023; Revised 12 June 2024; Accepted 24 August 2024

### บทคัดย่อ

**ความเป็นมาและวัตถุประสงค์ :** ในการหล่อเหล็กหล่อเหนียว การทำนายสมบัติเชิงกลของชิ้นงานที่ได้จากน้ำโลหะก่อนการเทน้ำเหล็กหล่อเหนียวลงแบบหล่อจะเป็นแนวทางในการผลิตแม่นยำตรงเชิงคุณภาพและการประหยัดค่าใช้จ่าย ทั้งนี้ ปัญญาประดิษฐ์น่าจะมีศักยภาพในการทำนายสมบัติของเหล็กหล่อเหนียวจากส่วนผสมทางเคมีได้ ในการวิจัยนี้ จึงได้ทดลองใช้ปัญญาประดิษฐ์ในการทำนายค่าความแข็งแรงดึงของชิ้นงานเหล็กหล่อเหนียวจากส่วนผสมทางเคมีด้วยอัลกอริทึม multi-linear regression และ multi-layer perceptron เพื่อศึกษาความเป็นไปได้ในการใช้ปัญญาประดิษฐ์ในการทำนายความแข็งแรงดึงจากส่วนผสมทางเคมี

**วิธีดำเนินการวิจัย :** ในการทำนายความแข็งแรงดึงจากส่วนผสมทางเคมีของเหล็กหล่อเหนียว ใช้ข้อมูลส่วนผสมทางเคมีที่ประกอบด้วยคาร์บอน ซิลิกอน แมงกานีส กำมะถัน แมกนีเซียม และทองแดง และความแข็งแรงดึงของชิ้นงานหล่อจากบทความวิชาการต่าง ๆ โดยชุดข้อมูลมีจำนวนทั้งสิ้น 55 ตัวอย่าง

**ผลการวิจัย :** จำนวนข้อมูลสอนมีผลต่อความแม่นยำในการทำนายของแบบจำลองที่ได้จากปัญญาประดิษฐ์ทั้งสองแบบ นอกจากนี้ การทำนายความแข็งแรงดึงด้วยแบบจำลองที่สร้างจากอัลกอริทึมประเภท multi-linear regression ยังบ่งชี้ว่าความเข้มข้นของคาร์บอนร่วมกับซิลิกอน และความเข้มข้นของแมงกานีส ทองแดง และซิลิกอน มีความสัมพันธ์กับความแข็งแรงดึง การใช้อัลกอริทึมแบบ multi-layer perceptron ที่มีการ

ปรับพารามิเตอร์ที่เหมาะสมให้ผลการทำนายที่ดีกว่าอัลกอริทึมแบบ multi-linear regression

**สรุป :** มีความเป็นไปได้ที่จะใช้ปัญญาประดิษฐ์ในการทำนายความแข็งแรงดึงของชิ้นงานเหล็กหล่อเหนียว

**การนำไปใช้ประโยชน์ในเชิงปฏิบัติ :** จากผลการศึกษาที่บ่งว่าสามารถนำปัญญาประดิษฐ์ไปใช้ในการทำนายความแข็งแรงดึงของชิ้นงานเหล็กหล่อเหนียว ทำให้ในอนาคตมีโอกาสนำแบบจำลองปัญญาประดิษฐ์ที่ได้รับการปรับปรุงไปใช้ในการทำนายสมบัติของเหล็กหล่อเหนียวในอุตสาหกรรมหล่อโลหะ

**คำสำคัญ :** ปัญญาประดิษฐ์, เหล็กหล่อเหนียว, การทำนาย, ความแข็งแรงดึง

## Abstract

**Background and Objectives:** In the process of ductile iron casting, predicting the mechanical properties of a cast sample from its compositions prior to pouring has been envisioned as a guideline for precision manufacturing and cost savings. Artificial intelligence holds potential for predicting the properties of ductile iron based on its chemical compositions. Thus, the present study tested the feasibility of using artificial intelligence to predict the tensile strength of ductile iron by using both multi-linear regression and multi-layer perceptron algorithms.

**Methodology:** In predicting the tensile strength from chemical compositions of ductile iron, a dataset comprising of six chemical compositions, i.e., carbon, silicon, manganese, sulfur, magnesium and copper, along with tensile strength data from various publications, were used. The datasets consisted of a total of 55 samples.

**Main Results:** The number of training datasets had an impact on the accuracy of predictions generated by both AI models. As per the results provided by the multi-linear regression algorithm, the carbon and silicon contents as well as the manganese, copper and silicon contents were significantly related to the tensile strength values. Use of the multi-layer perceptron model with appropriate parameters yielded better predictions when compared to the use of the multi-linear regression model.

**Conclusions:** Application of artificial intelligence to predict the tensile strength of ductile iron holds significant feasibility.

**Practical Application:** Based on the results, which indicate that artificial intelligence can be used to predict the tensile strength of ductile iron prior to casting, the artificial intelligence

model exhibits potential to expand to the prediction of properties of ductile iron in the casting industry.

**Keywords:** Artificial Intelligent, Ductile Iron, Prediction, Tensile Strength

## Introduction

ในปัจจุบันเหล็กหล่อเหนียว (Ductile Iron) ถูกนำมาใช้ในอุตสาหกรรมอย่างกว้างขวาง เช่น ชิ้นส่วนในปั๊มแรงดัน เพลาช้อเหวี่ยง ฯลฯ เนื่องจากความสามารถในการรับแรงที่สูง อีกทั้งยังสามารถยึดตัวได้มาก เมื่อเทียบกับเหล็กหล่อกราไฟต์ประเภทอื่น ๆ เหล็กหล่อเหนียวจำแนกเป็นชั้นคุณภาพต่าง ๆ ด้วยระดับของความแข็งแรงดึงและความสามารถในการยึดตัวตามมาตรฐานสากล เช่น มาตรฐาน ISO 1083 [1] หรือในบางครั้งอาจจะใช้ระดับความสามารถในการรับแรงกระแทก ความแข็งและโครงสร้างจุลภาคร่วมในการจำแนกประเภทก็ได้ อย่างไรก็ตาม มาตรฐานสากลของเหล็กหล่อเหนียวไม่ได้ระบุว่าเหล็กหล่อเหนียวแต่ละชั้นคุณภาพจะหล่อด้วยน้ำเหล็กส่วนผสมทางเคมีแบบใด ทำให้ผู้ผลิตสามารถกำหนดส่วนผสมทางเคมีได้ตามประสบการณ์ของตน อันนำมาซึ่งต้นทุนการผลิตที่แตกต่างกัน เนื่องจากหลักการพื้นฐานทางวัสดุศาสตร์สมบัติเชิงกลของวัสดุต่าง ๆ ขึ้นกับโครงสร้างจุลภาคของวัสดุที่ปรากฏอยู่ทั้งในเชิงปริมาณและลักษณะ โดยโครงสร้างจุลภาคของวัสดุจะเปลี่ยนแปลงไปตามกระบวนการผลิต ส่วนประกอบทางเคมี และการอบชุบ อย่างไรก็ตามในการผลิตชิ้นงานเหล็กหล่อเหนียวนั้นปัจจัยด้านกระบวนการผลิต เช่น ขนาดชิ้นงาน ไม่มีผลต่อสมบัติเชิงกลที่ตกลงซื้อขายกัน เพราะปกติการทดสอบสมบัติเชิงกลในชิ้นงานเหล็กหล่อเหนียวนั้นมักทดสอบกับชิ้นงานหล่อตามมาตรฐานสำหรับการนำมาทดสอบ ขณะที่ชิ้นงานเหล็กหล่อเหนียวนั้นมักจะนำไปใช้งานโดยตรงเลยไม่ค่อยทำการอบชุบทางความร้อน ยกเว้นการผลิตเหล็กหล่อเหนียวบอบอบสเต็มเปอร์ริงเท่านั้น ทำให้ในการผลิตเหล็กหล่อเหนียวชั้นคุณภาพหนึ่ง ๆ ผู้ผลิตเหล็กหล่อจึงเลือกปรับส่วนผสมทางเคมี เพื่อให้ได้โครงสร้างจุลภาค และสมบัติเชิงกลตามที่ต้องการเป็นหลัก

อย่างไรก็ตาม ในการผลิตเหล็กหล่อเหนียว ผู้ผลิตในไทยนิยมใช้วัตถุดิบหลัก คือ เศษเหล็กกล้าหลากหลายชั้นคุณภาพขึ้นกับความสามารถในการหาเศษเหล็กกล้ามาผลิตเหล็กหล่อเหนียว ส่งผลให้การปรับส่วนผสมทางเคมีให้คงที่ทำได้ยาก ส่วนผสมทางเคมีของน้ำเหล็กหล่อจึงมีการแปรเปลี่ยนไปตามเศษเหล็กกล้าที่นำไปหลอมขณะที่ส่วนผสมทางเคมีที่ส่งผลกระทบต่อโครงสร้างจุลภาคในเหล็กหล่อเหนียวมีอยู่ด้วยกันหลายธาตุ เช่น คาร์บอน ซิลิกอน แมงกานีส กำมะถัน แมกนีเซียม ทองแดง และอื่น ๆ เมื่อเป็นเช่นนี้เพื่อให้การผลิตเหล็กหล่อเหนียวได้ชั้นคุณภาพตามต้องการ ผู้ผลิตเหล็กหล่อเหนียว จึงเลือกวิธีการกำหนดกรอบส่วนผสมทางเคมีในการผลิต อย่างไรก็ตามการหลอมให้ได้ส่วนผสมตามกรอบการผลิตนั้นทำได้ยากในครั้งเดียวจึงยังไม่ประสบปัญหาการหล่อไม่ได้ชั้นคุณภาพเป็นระยะ ก่อให้เกิดความพยายามค้นหาวิธีการใหม่ ๆ ในการควบคุมคุณภาพน้ำเหล็กหล่อเหนียวเพื่อหล่อให้ได้เหล็กหล่อเหนียวตามชั้นคุณภาพที่ต้องการ ผู้วิจัยพบว่า ปัญญาประดิษฐ์ หรือ Artificial Intelligence เป็นเทคนิคใหม่ที่น่าจะนำมาใช้ในการคาดการณ์สมบัติของเหล็กหล่อเหนียวที่ได้จากส่วนผสมทางเคมีทดแทนการกำหนดกรอบส่วนผสมทางเคมีได้ ดังจะเห็นได้จากความพยายามประยุกต์

ใช้ปัญญาประดิษฐ์ในการช่วยคาดการณ์ส่วนผสมของน้ำเหล็กหล่อเหนียวที่เหมาะสมกับการผลิตชิ้นงานขนาดต่าง ๆ [2] และความพยายามในการใช้ปัญญาประดิษฐ์ในการทำนายค่าความแกร่งของเหล็กหล่อเหนียวจากส่วนผสมทางเคมีและอัตราการเย็นตัว [3] อย่างไรก็ตามยังไม่มีงานวิจัยที่พยายามนำปัญญาประดิษฐ์มาใช้เพื่อควบคุมคุณภาพน้ำเหล็กหล่อเหนียวผ่านการทำนายสมบัติเหล็กหล่อเหนียวจากส่วนผสมทางเคมี และเพื่อที่จะยืนยันแนวคิดดังกล่าวผู้วิจัยจึงได้ทำการศึกษาขึ้น ด้วยวัตถุประสงค์ในการทดสอบศักยภาพของปัญญาประดิษฐ์ในการทำนายสมบัติทางกลของเหล็กหล่อเหนียวจากส่วนผสมทางเคมีของเหล็กหล่อเหนียวขึ้น

## Research Procedures

ในการศึกษาที่ใช้อัลกอริทึมของการเรียนรู้ด้วยเครื่องจักร 2 ประเภท คือ multi-linear regression และ multi-layer perceptron ทั้งสองอัลกอริทึมถูกนำมาใช้ในการเรียนรู้ และประเมินความเป็นไปได้ในการทำนายความแข็งแรงดึงของชิ้นงานเหล็กหล่อจากส่วนผสมทางเคมี โดยรายละเอียดพื้นฐานของอัลกอริทึมทั้งสองมีดังนี้

### Multi-layer perceptron algorithm

Multi-linear regression คือ การวิเคราะห์ การถดถอยพหุคูณ อัลกอริทึมนี้เป็นการเรียนรู้ความสัมพันธ์ของตัวแปรตั้งแต่ 2 ตัวขึ้นไป โดยตัวแปรอิสระจะมีมากกว่า 1 ตัว แทนด้วย  $x_1, x_2, \dots, x_n$  ส่วนตัวแปรตามจะมี 1 ตัวเท่านั้น แทนค่าด้วย  $y$  โดยความสัมพันธ์ของ  $x_1, x_2, \dots, x_n$  และ  $y$  อธิบายได้ด้วยสมการที่ 1 ดังนี้

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_n x_n \quad (1)$$

โดยที่

$y$	คือ ตัวแปรตาม
$x_1, x_2, \dots, x_n$	คือ ตัวแปรอิสระ
$\beta_0$	คือ จุดตัดแกน
$\beta_1, \beta_2, \dots, \beta_n$	คือ สัมประสิทธิ์

## Multi-layer perceptron algorithm

Multi-layer perceptron เป็นอัลกอริทึมรูปแบบหนึ่งของโครงข่ายประสาทเทียม มีโครงสร้างของหน่วยย่อยของโครงข่ายประสาทเป็นแบบหลายชั้น โดยมีกระบวนการเรียนรู้และฝึกฝนเป็นแบบมีผู้สอน (Supervise learning) กระบวนการเรียนรู้และฝึกฝนประกอบด้วย 2 ส่วนย่อยคือ การส่งผ่านข้อมูลไปข้างหน้า (Forward propagation) และการส่งผ่านย้อนกลับ (Back propagation) สำหรับการส่งผ่านข้อมูลไปข้างหน้า ข้อมูลจะผ่านเข้าโครงข่ายประสาทเทียม การทำงานของอัลกอริทึม คือ เซลล์ประสาทหลายชั้นที่เชื่อมต่อถึงกัน โดยแต่ละชั้นจะเปลี่ยนอินพุตจากชั้นก่อนหน้าและสร้างเอาต์พุตสำหรับชั้นถัดไป ฟังก์ชันการเปิดใช้งานทำให้เกิดความไม่เชิงเส้นในเครือข่าย ในการสร้างแบบจำลองความสัมพันธ์ที่ซับซ้อนระหว่างอินพุตกับเอาต์พุต เริ่มต้นที่ชั้นข้อมูลขาเข้าหรือบัพอินพุต (Input Nodes) และจะส่งผ่านเข้าสู่ชั้นเรียนรู้ (Hidden Layers) จากอีกชั้นหนึ่งไปสู่อีกชั้นหนึ่งจนกระทั่งถึงชั้นข้อมูลออกหรือบัพเอาต์พุต (Output nodes) ภายใต้ชั้นเรียนรู้สามารถปรับค่าน้ำหนักของการเชื่อมต่อ (Learning Weight) และการตั้งค่ากฎการแก้ไขข้อผิดพลาด (Error-Correction) กระบวนการนี้ให้ผลต่างของผลตอบที่แท้จริง (Actual Response) กับผลตอบเป้าหมาย (Target Response) เกิดเป็นสัญญาณผิดพลาด (Signal Error) ซึ่งสัญญาณผิดพลาดนี้จะถูกส่งย้อนกลับเข้าสู่โครงข่ายประสาทเทียมในทิศทางตรงกันข้ามกับการเชื่อมต่อ และค่าน้ำหนักของการเชื่อมต่อจะถูกปรับจนกระทั่งผลลัพธ์ที่ได้ใกล้เคียงกับเป้าหมายดัง Figure 1




Figure 1 Multi-layer perceptron

สำหรับการดำเนินการศึกษานั้นผู้วิจัยได้ดำเนินการตามแผนภูมิใน Figure 2 โดยเริ่มจากการเก็บรวบรวมข้อมูลของส่วนผสมทางเคมี และความแข็งแรงดึงของชิ้นงานหลังจากงานวิจัยที่มีการเผยแพร่ในบทความวิชาการต่าง ๆ โดยที่ข้อมูลที่จะถูกเก็บรวบรวมจะต้องประกอบไปด้วย ส่วนผสมทางเคมีของธาตุจำนวน 6 ธาตุ อันประกอบด้วย คาร์บอน ซิลิกอน แมงกานีส แมกนีเซียม กำมะถัน และทองแดง พร้อมทั้งความแข็งแรง

แรงดึงของชิ้นงานที่ได้จากการหล่อ ในการเก็บรวบรวมข้อมูลดังกล่าวผู้วิจัยสามารถรวบรวมข้อมูลได้จำนวน 55 ชุดข้อมูลจากบทความจำนวน 4 บทความ [4-7] ดังแสดงตัวอย่างของชุดข้อมูลดัง Table 1 หลังจากได้ชุดข้อมูลแล้วผู้วิจัยได้นำข้อมูลมาจัดลงในโปรแกรม excel เพื่อให้ง่ายต่อการนำไปจัดการข้อมูลในขั้นตอนถัดไป หลังจากนั้นผู้วิจัยได้พัฒนาโค้ดปัญญาประดิษฐ์ด้วยภาษา python ภายใต้ Integrated Development Environment ของ PyCharm โดยในโค้ดผู้วิจัยพัฒนาโค้ดเพื่อการแบ่งตัวแปรต้นอันประกอบด้วยส่วนผสมทางเคมี และตัวแปรตามคือ ความแข็งแรงดึงของเหล็กหล่อเหนียวของชุดข้อมูลที่ได้รวบรวมมาหลังจากนั้นผู้วิจัยได้แบ่งชุดข้อมูลออกเป็น 2 ชุด เพื่อนำไปใช้ 1) เรียนรู้ฐานข้อมูลเพื่อสร้างแบบจำลองด้วยปัญญาประดิษฐ์ และ 2) ทดสอบแบบจำลองที่ได้จากปัญญาประดิษฐ์ ทำให้ชุดข้อมูลตัวแปรต้นสอน ตัวแปรต้นทดสอบ ตัวแปรตามสอน ตัวแปรตามทดสอบ โดยสัดส่วนของการใช้ชุดข้อมูลสอนแบบสุ่มอัตโนมัติกับชุดข้อมูลทดสอบเพื่อการสร้างแบบจำลองด้วยปัญญาประดิษฐ์ในการศึกษานี้ คือ 70 : 30 และ 80 : 20 หลังจากนั้นผู้วิจัยได้ดำเนินการจำลองด้วยอัลกอริทึมสองแบบเพื่อสร้างแบบจำลองอธิบายผลของส่วนผสมทางเคมีต่อความแข็งแรงดึง และทดสอบแบบจำลองโดยการนำมาคำนวณค่าความผิดพลาดสมบูรณ์เฉลี่ย

อนึ่ง ในการสร้างแบบจำลองด้วยอัลกอริทึมทั้งสองใช้ตัวแปรต้น (ประกอบด้วยส่วนผสมทางเคมีทั้งหมด) เพื่อนำมาสร้างแบบจำลองและทดสอบแบบจำลอง แต่เพื่อให้ทราบถึงอิทธิพลของตัวแปรต้นในการสร้างแบบจำลองด้วยอัลกอริทึมแบบ Multi-linear regression ผู้วิจัยทดลองใช้ตัวแปรต้นที่ประกอบไปด้วยส่วนผสมทางเคมีอีก 5 แบบ คือ 1) คาร์บอน ซิลิกอน แมงกานีส แมกนีเซียม กำมะถัน และทองแดง 2) คาร์บอน และ ซิลิกอน 3) แมงกานีส แมกนีเซียม และ กำมะถัน 4) แมงกานีส ซิลิกอน และ ทองแดง 5) แมกนีเซียม และกำมะถัน โดยในการจำลองได้ใช้สัดส่วนของการใช้ชุดข้อมูลสอนต่อชุดข้อมูลทดสอบเพื่อการสร้างแบบจำลองด้วยปัญญาประดิษฐ์ 80 : 20 เท่านั้น เพื่อประเมินหาความสัมพันธ์และอิทธิพลของธาตุผสมของเหล็กหล่อเหนียวต่อความแข็งแรง

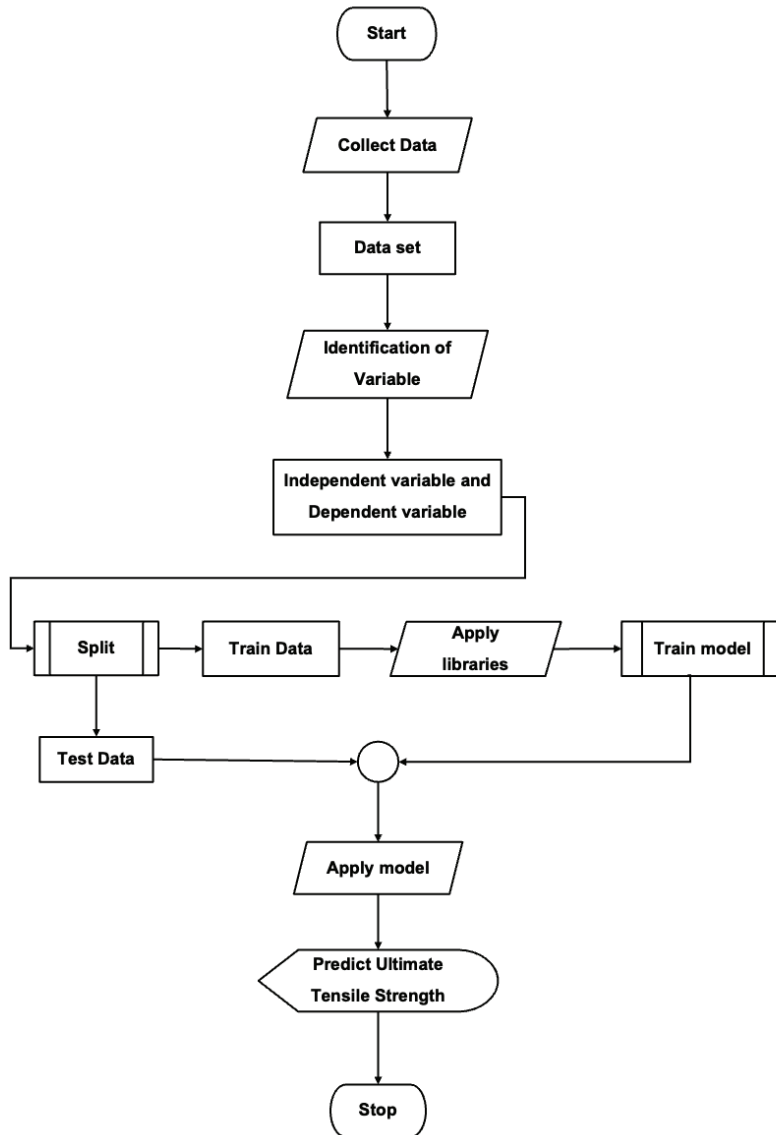


Figure 2 Overall study procedures

## Results and Discussion

ด้วยในการศึกษาเป็นความเป็นไปได้ในการทำนายความแข็งแรงดึงของเหล็กหล่อเหนียวด้วยปัญญาประดิษฐ์ จากส่วนผสมทางเคมี ผู้วิจัยได้แบ่งผลการทดสอบเป็นสองกรณี คือ 1) เพื่อตรวจสอบผลของธาตุผสมที่เป็นองค์ประกอบของชุดข้อมูลส่วนผสมทางเคมีที่มีผลต่อความสัมพันธ์ความแข็งแรงดึงของเหล็กหล่อเหนียว และ 2) เพื่อตรวจสอบผลของจำนวนชุดข้อมูลที่มีผลต่อการทำนายค่าความแข็งแรงดึงของเหล็กหล่อเหนียว ประเภทอัลกอริทึมที่มีผลต่อการทำนายด้วยแบบจำลองปัญญาประดิษฐ์ที่สร้างขึ้น โดยรายละเอียดของผลการทดลองแสดงดังต่อไปนี้

### การเปรียบเทียบผลของธาตุผสมต่อการทำนายความแข็งแรงดึงด้วยอัลกอริทึม Multi-linear regression

เพื่อตรวจสอบความสัมพันธ์ของธาตุผสมต่อความแข็งแรงดึงของชิ้นงานนั้น ผู้วิจัยได้ดำเนินการแบ่งธาตุเป็นกลุ่ม ๆ จำนวน 5 กลุ่ม คือ 1) ทุกธาตุที่เลือกมาเป็นฐานข้อมูล 2) ธาตุคาร์บอน และซิลิกอน ซึ่งเป็นกลุ่มธาตุผสมที่มีผลต่อปริมาณกราไฟต์ 3) ธาตุแมงกานีส แมกนีเซียม และกำมะถัน ซึ่งเป็นกลุ่มธาตุที่มีผลต่อจำนวนเม็ดกราไฟต์ 4) ธาตุ แมงกานีส ซิลิกอน และทองแดง ซึ่งเป็นธาตุที่มีผลต่อการก่อตัวของเนื้อพื้น และ 5) ธาตุแมกนีเซียม และกำมะถัน ซึ่งเป็นธาตุที่มีผลต่อความกลมของกราไฟต์ และนำกลุ่มธาตุที่แบ่งมาทำการสอน เพื่อสร้างแบบจำลองปัญญาประดิษฐ์แบบ Multi-linear regression ผลการทดสอบแบบจำลองปัญญาประดิษฐ์ได้ผลการทดสอบดัง Figure 3 จาก Figure 3 แสดงค่าทำนายจากแบบจำลอง ปัญญาประดิษฐ์ (จุดสีชมพู) กับค่าจากข้อมูลจริง (จุดสีน้ำเงิน) โดย Figure 2a) แสดงผลของกลุ่มธาตุผสมทุกตัว Figure 2b) แสดงผลของกลุ่มธาตุคาร์บอนและซิลิกอน Figure 2c) แสดงผลของกลุ่มธาตุ แมงกานีส แมกนีเซียม และกำมะถัน Figure 2d) แสดงผลของกลุ่มธาตุ แมงกานีส ซิลิกอน และทองแดง และ Figure 2e) แสดงผลของกลุ่มธาตุ แมกนีเซียม และกำมะถัน

**Table 1** Examples of dataset of ductile iron (unit of concentration: % w/w)

Sample No.	Chemical Compositions						Ultimate tensile strength (MPa)
	C	Si	Mn	Cu	S	Mg	
1	3.5	2.05	0.18	0.03	0.01	0.05	475
2	3.55	2.15	0.19	0.026	0.009	0.045	473
3	3.6	2.25	0.18	0.028	0.011	0.04	471
....	3.66	2.47	0.194	0.147	0.0123	0.034	456
....	3.67	2.48	0.191	0.377	0.0101	0.045	531
....	3.66	2.45	0.199	0.735	0.0085	0.032	615
55	3.65	1.95	0.3	1.25	0.009	0.059	579

พิจารณา Figure 3b-3e ถ้าการกระจายตัวของจุดสีส้มซึ่งเป็นค่าความแข็งแรงดึงจากการทำนาย และจุดสีน้ำเงินที่เป็นค่าจากข้อมูลจริงอยู่ใกล้เคียงกันมากที่สุดหมายความว่าค่าที่ได้จากการทำนายใกล้เคียงกับค่าจริง นั้นจะเห็นได้ว่าการเลือกใช้กลุ่มธาตุผสมคาร์บอนและซิลิกอน และ กลุ่มธาตุผสมแมงกานีส ทองแดง ซิลิกอน ในการทำนายความแข็งแรงดึงของเหล็กหล่อเหนียวจะได้ค่าความแข็งแรงดึงจากการทำนายใกล้เคียงกับค่าจริงมากที่สุดเมื่อเทียบกับการเลือกกลุ่มธาตุผสมอื่น ๆ ซึ่งอนุมานได้ว่ากลุ่มธาตุทั้งสองน่าจะมีผลต่อการก่อตัวของโครงสร้างจุลภาคที่ส่งผลอย่างมากต่อความแข็งแรงของเหล็กหล่อเหนียว โดยกลุ่มธาตุคาร์บอนและซิลิกอนที่เป็นธาตุที่มีผลหลักต่อปริมาณของ กราไฟต์ในโครงสร้างจุลภาคของเหล็กหล่อ




เหนียว ซึ่งการเพิ่มปริมาณของ กราไฟต์จะลดปริมาณของเนื้อพื้นที่แข็งแรงกว่าลง และการเพิ่มปริมาณ กราไฟต์เกิดจากการเพิ่มปริมาณของคาร์บอน ในขณะที่ในการผลิตเหล็กหล่อเหนียวนั้นผู้ผลิตมักจะควบคุม ให้ได้ค่าเปอร์เซ็นต์คาร์บอนเทียบเท่า (%CE) อยู่ในช่วง 4.3-4.4 เพื่อป้องกันการเกิดการหดตัวของเหล็กหล่อ เหนียวขณะแข็งตัว หรือเกิดโครงสร้างจุลภาคที่แข็ง โดยเปอร์เซ็นต์คาร์บอนเทียบเท่าหาได้จากสมการที่ 2


$$\%CE = C + \frac{1}{3(Si)} \quad (2)$$

จากสมการที่ 2 ถ้าผู้ผลิตควบคุมค่าคาร์บอนเทียบเท่าในช่วงที่กำหนดการเพิ่มปริมาณคาร์บอนจะทำให้ ต้องลดปริมาณของซิลิกอน และเพื่อยืนยันว่าสมมุติฐานที่น่าจะเป็นจริงผู้วิจัยจึงได้ตรวจสอบความสัมพันธ์ของ ความแข็งแรงดึงของเหล็กหล่อเหนียวกับปริมาณธาตุคาร์บอน และซิลิกอน ได้ผลดัง Figure 4 จาก Figure 4.a) จะเห็นได้ว่าปริมาณคาร์บอนที่เพิ่มขึ้นเหล็กหล่อเหนียวจะมีความแข็งแรงดึงลดลง ขณะที่การเพิ่มขึ้น ของซิลิกอนมีผลเพิ่มความแข็งแรงดึงของเหล็กหล่อเหนียว ดัง Figure 4.b) สำหรับกรณีของกลุ่มธาตุผสม แมงกานีส ทองแดง และซิลิกอนนั้น เป็นกลุ่มธาตุที่มีผลต่อเนื้อพื้นที่ได้หลังการหล่อของเหล็กหล่อเหนียว เนื้อ พื้นที่ประกอบไปด้วยเฟอร์ไรท์จะแข็งแรงน้อยกว่าเฟอร์ไรท์ อย่างไรก็ตามผลของธาตุกลุ่มนี้มีทั้งโปรโมทให้ เกิดเฟอร์ไรท์และเฟอร์ไรท์ด้วยความแรงในทางทฤษฎีต่างกันจึงไม่สามารถนำเฉพาะธาตุผสมมาสร้างความ สัมพันธ์กับความแข็งแรงได้เหมือนกับกลุ่มที่เพิ่มปริมาณกราไฟต์


อย่างไรก็ตาม ในการศึกษาวิจัยไม่ได้ดำเนินการทดลองเพื่อทดสอบยืนยันตามสมมุติฐานนี้อย่างสมบูรณ์ แต่ต้องการแสดงให้เห็นว่าเรามีโอกาสใดบ้างในการประยุกต์ใช้ปัญญาประดิษฐ์ช่วยพัฒนาชั้นคุณภาพเหล็ก หล่อเหนียวใหม่ ๆ ในอนาคต เช่น การลดปริมาณคาร์บอนเพื่อลดปริมาณกราไฟต์ ฯลฯ นอกจากนี้จาก Figure 3.a) จะเห็นว่าการเลือกใช้ทุกธาตุผสมในการทำนายความแข็งแรงของเหล็กหล่อเหนียวให้ผลการ ทำนายที่ดีที่สุดเมื่อเทียบการเลือกใช้เฉพาะกลุ่มธาตุผสมบางตัว




a) All elements




b) Carbon, and Silicon



c) Manganese, Magnesium, and Sulfur

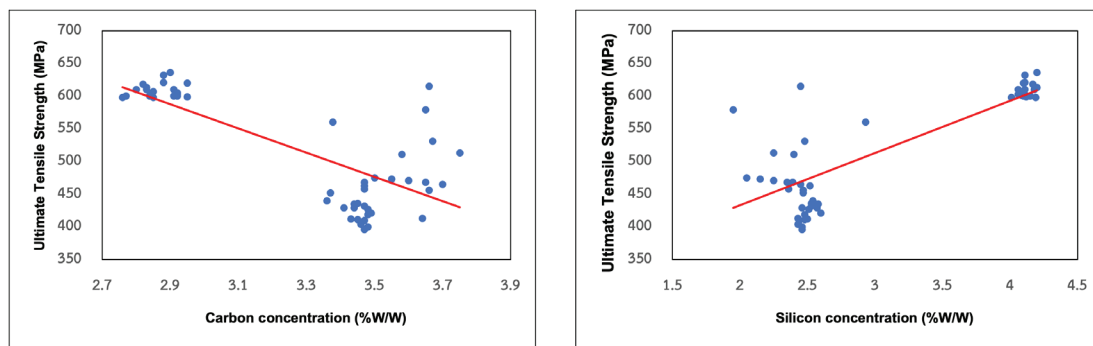


d) Manganese, Copper and Silicon



e) Magnesium, and Sulfur

**Figure 3** Tensile strength of dustile iron as predicted by Multi-linear regression compared with actual data when using various groups of predictors



a) Carbon

b) Silicon

**Figure 4** Relationship between a) carbon content and b) silicon content and tensile strength of ductile iron

### ผลของจำนวนชุดข้อมูลสอน ประเภทอัลกอริทึม ต่อผลการทำนายความแข็งแรง

ในการศึกษาผลของจำนวนชุดข้อมูลสอน และ ประเภทอัลกอริทึมต่อความสามารถในการทำนายความแข็งแรง ดังนั้น ผู้วิจัยประเมินความสามารถในการทำนายจากค่าความผิดพลาดสัมบูรณ์เฉลี่ยของการทำนายด้วยแบบจำลองทั้งแบบ Multi-linear regression และ Multi-layer perceptron จากการสอนแบบจำลองด้วยสัดส่วนชุดข้อมูลสอนต่อชุดข้อมูลทดสอบเป็น 70:30 และ 80:20 และใช้พารามิเตอร์ในการจำลองด้วย Multi-layer perceptron ดัง Table 2 ซึ่งเป็นค่าพารามิเตอร์ที่ให้ผลการทำนายที่ดีที่สุดในการศึกษา

จากผลการเปรียบเทียบค่าความผิดพลาดสัมบูรณ์เฉลี่ย (Mean Absolute Error) ของแบบจำลองปัญหาประติษฐ์แบบ Multi-linear regression และ แบบ Multi-layer perceptron ดังแสดงใน Figure 5 นั้น จะเห็นได้ว่าจำนวนชุดข้อมูลมีผลต่อการทำนายความแข็งแรงของเหล็กหล่อเหนียวโดยสัดส่วนของจำนวนชุดข้อมูลใช้สอนมากขึ้นจะให้ค่าที่ทำนายได้มีค่าความผิดพลาดสัมบูรณ์เฉลี่ยลดลง ด้วยเหตุนี้จึงอาจจะกล่าวได้ว่าขนาดของชุดข้อมูลสอนมีผลต่อความสามารถในการทำนายของแบบจำลองปัญหาประติษฐ์ที่สร้างขึ้น นอกจากนี้ถ้าเปรียบเทียบแท่งกราฟระบายน้ซึ่งเป็นค่าความผิดพลาดเฉลี่ยของการทำนายด้วยแบบจำลองปัญหาประติษฐ์แบบ Multi linear regression กับแท่งระบายน้ซึ่งแสดงค่าความผิดพลาดสัมบูรณ์เฉลี่ยของการทำนายของแบบจำลองปัญหาประติษฐ์แบบ Multi-layer perceptron พบว่า ณ สัดส่วนของชุดข้อมูลที่นำมาใช้ในการสอนเดียวกันเพื่อสร้างแบบจำลองแท่งระบายน้จะต่ำกว่าระบายน้ซึม และแท่งระบายน้ให้ค่าความผิดพลาดสัมบูรณ์เฉลี่ยต่ำสุดประมาณ 16 เมื่อใช้สัดส่วนข้อมูลสอน 80:20 จึงอาจจะกล่าวได้ว่า ปัญหาประติษฐ์ประเภท Multi-layer perceptron ให้ผลการทำนายที่ดีกว่า ปัญหาประติษฐ์ประเภท Multi-linear regression นอกจากนี้ในการศึกษานี้ และถ้านำค่าต่ำสุดของค่าความผิดพลาดสัมบูรณ์เฉลี่ยของการทำนายไปเทียบกับเกณฑ์แบ่งชั้นคุณภาพของเหล็กหล่อเหนียว [1] ในชั้นคุณภาพที่ติดกันซึ่งใช้ค่าความแข็งแรงดึงที่แตกต่างกัน 50 MPa ผู้วิจัยจึงเชื่อว่าปัญหาประติษฐ์จึงมีโอกาสนำมาประยุกต์ใช้ในการนำค่าส่วนผสมทางเคมีมาทำนายความแข็งแรงเพื่อการบ่งชี้คุณภาพได้

## Summaries

จากการศึกษาผู้วิจัยพบว่าการทำนายค่าความแข็งแรงดึงของเหล็กหล่อเหนียวจากความเข้มข้นของคาร์บอนและซิลิกอน และค่าความเข้มข้นของแมงกานีส ทองแดง และซิลิกอน มีความผิดพลาดน้อยกว่าเมื่อเทียบกับการเลือกใช้กลุ่มธาตุผสมอื่น ๆ ทำให้เรา อนุมานได้ว่าความแข็งแรงของเหล็กหล่อเหนียวขึ้นอยู่กับธาตุผสมที่ส่งผลต่อโครงสร้างจุลภาคหลัก ๆ ที่ปรากฏ นอกจากนี้ขนาดของข้อมูลที่ใช้สอนเพื่อสร้างแบบจำลองปัญญาประดิษฐ์นั้น มีผลต่อความสามารถในการทำนายของแบบจำลองปัญญาประดิษฐ์ที่สร้างขึ้น สุดท้าย จากผลการทำนายที่จำนวนชุดข้อมูล 55 ชุดข้อมูล แบบจำลองปัญญาประดิษฐ์ที่สร้างขึ้นด้วยMulti-layer perceptron ที่เลือกใช้พารามิเตอร์ที่เหมาะสมสามารถทำนายความแข็งแรงดึงได้ความผิดพลาดสมบูรณ์เฉลี่ยเพียงแค่ประมาณ 16 MPa ซึ่งน้อยกว่าเกณฑ์การแบ่งประเภทชั้นคุณภาพเหล็กหล่อเหนียวที่ 50 MPa จึงสรุปได้ว่าปัญญาประดิษฐ์มีความเป็นไปได้ที่จะใช้ทำนายความแข็งแรงดึงของเหล็กหล่อเหนียวจากส่วนผสมทางเคมี

**Table 2** Multi-layer perceptron parameters used in the study

Parameters	Values
Teaching data/Total data ratio	0.8
Maximum cycles for simulation	100,000
Error tolerance	0.0001
Activation function for the hidden layer	relu
The solver for weight optimization	adam
Number of hidden layer neurons	100
Number of input layer neurons (I)	7
Number of output layer neurons (O)	1



**Figure 5** Mean Absolute Error obtained with Multi-linear regression and Multi-layer perceptron algorithms

## References

1. International ISO Standard, 2004, ISO 1083:2004E, Spheroidal Graphite Cast Irons Classification, pp. 1-7.
2. Palatto, L.F., Gutiérrez, L., Vargas, E. and Bertha, L., 2020, "A Methodology for Optimization of Mechanical Properties of Automotive Iron-Casting Brakes using Artificial Neural Networks," *Procedia Manufacturing*, 52, pp. 162-167.
3. Song, L., Zhang, H., Zhang, J. and Guo, H., 2024, "Prediction of Heavy-section Ductile Iron Fracture Toughness Based on Machine Learning," *Scientific Reports*, 14 (4681). <https://doi.org/10.1038/s41598-024-55089-3>
4. Behera, R.K., Swain, S.K., Sen, S. and Mishra, S.C., 2013, "Property Prediction of Ductile Iron (DI): Artificial Neural Network Approach," *Orissa Journal of Physics*, 20 (2), pp. 217-224.
5. Çehiz, C., 2019, Cooling Curve Thermal Analysis and Oxygen Activity, Master of Natural and Applied Sciences Thesis, Middle East Technical University, 105 p.
6. Vitor, E.A.A., 2015, Use of Thermal Analysis to Control the Solidification Morphology of Nodular Cast Irons and Reduce Feeding Needs, Doctoral of Mechanical and Process Engineering Thesis, University of Duisburg-Essen, 182 p.
7. Swain, S.K., 2008, Effect of Chemistry and Processing Variables on the Mechanical Properties of Thin-wall Ductile Iron Castings, Master of Metallurgical and Materials Engineering Thesis, National Institute of Technology Rourkela, 86 p.