

المحاضرة السادسة :

الشبكات العصبية في تحليل الأسواق المالية

من إعداد الدكتور: جيلالي بوزياني
أستاذ محاضر قسم "أ"
كلية العلوم الاقتصادية
جامعة خميس مليانة

الدكتور بوزياني جيلالي +
أستاذ محاضر "أ" كلية العلوم الاقتصادية
جامعة خميس مليانة

أصبحت الشبكات العصبية من أهم أدوات التنبؤ المالي بفضل قدرتها على التعلم من البيانات الضخمة واكتشاف الأنماط المخفية التي لا يراها التحليل التقليدي. تُستخدم أكبر المؤسسات المالية اليوم نماذج مبنية على الشبكات العصبية لتحليل أسعار الأسهم، وأسعار الصرف، والمؤشرات العالمية وعقود السلع الدولية (النفط - الذهب)، ومحافظ الاستثمار

أولاً: مفهوم الشبكات العصبية (Artificial Neural Networks - ANN):

1. تعريف الشبكات العصبية: هي نماذج حاسوبية متقدمة في مجال الذكاء الاصطناعي، مستوحاة من بنية وعمل الدماغ البشري. تهدف هذه الشبكات إلى محاكاة قدرة الدماغ: على التعلم، ومعالجة المعلومات، والتعرف على الأنماط المعقدة دون الحاجة إلى برمجة صريحة لكل مهمة. حيث تقوم فكرة الشبكات العصبية على إنشاء نظام تكيفي يمكنه اكتساب المعرفة من خلال عملية التعلم من البيانات التجريبية. بدلاً من اتباع مجموعة صارمة من التعليمات المبرمجة مسبقاً، تتعلم الشبكة كيفية ربط المدخلات بالمخرجات واكتشاف العلاقات المعقدة وغير الخطية بين المتغيرات.

2. المكونات الرئيسية:

تتكون الشبكة العصبية من مجموعة كبيرة من العقد المترابطة، والتي تُسمى "العصبونات الاصطناعية" (Neurons) وتنظم هذه العصبونات في طبقات :

- **طبقة الإدخال (Input Layer):** تتلقى البيانات الأولية من العالم الخارجي.
- **الطبقات المخفية (Hidden Layers):** توجد بين طبقة الإدخال والإخراج، وتقوم بمعالجة وتحليل البيانات من خلال سلسلة من العمليات الحسابية المعقدة. قد تحتوي الشبكة على طبقة مخفية واحدة أو عدة طبقات (وهذا ما يُعرف بالتعلم العميق).
- **طبقة الإخراج (Output Layer):** تُقدم النتيجة النهائية أو التنبؤ أو القرار بناءً على المعالجة التي تمت في الطبقات السابقة .

ثانياً: مزايا استخدام الشبكات العصبية في تحليل الأسواق المالية

- التعامل مع البيانات غير الخطية
- القدرة على التقاط الأنماط الدقيقة
- توقع الاتجاهات
- التكيف مع تغيرات السوق

- تحسين أداء التداول مقارنة بالمؤشرات التقليدية

فالأسواق تحتاج نماذج تتعامل مع تقلبات - ضوضاء - انعكاسات، وهو ما تتقنه الشبكات العصبية.

ثالثاً: بيانات الشبكات العصبية:

تتفرع بيانات الشبكات العصبية إلى أقسام:

1) البيانات السعرية (Raw Price Data) : هذه أبسط وأهم بيانات

الشبكة العصبية التي تتعامل مع السلاسل الزمنية ووجود OHLCV وهو مصطلح شامل يتضمن نقاط البيانات الخمس المهمة: الافتتاح والأعلى، والأدنى، والإغلاق، والحجم والمستخدم في تحليل نشاط سوق الأدوات المالية خلال فترة زمنية محددة. تُعد هذه المجموعة من البيانات بالغة الأهمية للمتداولين والمحللين، إذ توفر لمحة عامة عن ديناميكيات تداول الأوراق المالية.

1.1 سعر الافتتاح (Open) : يمثل التوازن الأولي بين العرض والطلب.

في الأسواق المتذبذبة مؤشراً مبكراً على قوة الاتجاه اليومي.

2.1 أعلى سعر (High): مهم لقياس: قوة المشتري، الحدود العليا للتذبذب، إمكانية الاختراق.

Breakout

الشبكات العصبية تستخدمه لحساب:

$$\text{Breakout Probability} = f(\text{High} / \text{Previous Resistance})$$

3.1 أقل سعر (Low): مؤشر على الحد الأدنى للضغط البيعي.

يستعمل في بناء مستويات الدعم. Support.

4.1 سعر الإغلاق (Close): هو أقوى إشارة سعرية لأنه يعكس أين انتهى التوازن، وأي طرف فاز

(بيع/شراء)، ويحدد اتجاه الشموع، لذلك تعتمد معظم النماذج على الإغلاق فقط.

5.1 حجم التداول (Volume): يعطي "وزن الاتجاه".

لأن الأسعار بدون حجم تُعتبر ضعيفة وغير موثوقة.

تعتبر OHLCV مهمة للشبكات العصبية، لأنها توفر: الاتجاه Trend، والتذبذب Volatility،

الزخم Momentum، السيولة Liquidity، قوة الاختراق Breakout Strength.

2. المؤشرات الفنية (Technical Indicators)

هي بيانات تساعد النموذج على التقاط سلوك السعر دون الحاجة لتعلمه من الصفر.

1.2 مؤشر القوة النسبية (RSI):

معادلته:

$$RSI = 100 - [100 / (1 + RS)]$$

حيث

$$RS = (\text{متوسط الارتفاعات} / \text{متوسط الانخفاضات})$$

يفيد الشبكة:

❖ يلتقط حالات التشبع الشرائي/البيعي

❖ يعطي معلومات دقيقة عن انعكاس الاتجاه

❖ يساعد LSTM في تحديد "مستوى قوة الاتجاه"

2.2 مؤشر تقارب وتباعد المتوسط المتحرك MACD: يعمل عن طريق تتبع العلاقة بين متوسطين

متحركين أسيين (EMA) لسعر الأصل، وهو مؤشر "متأخر" يتبع حركة السعر، ويستخدم غالباً مع مؤشرات أخرى لتأكيد الإشارات في الأسواق المتقلبة.

$$MACD = EMA12 - EMA26$$

$$Signal = EMA9$$

يفيد الشبكة:

❖ قياس زخم السوق وتحديد الاتجاهات المحتملة ونقاط الدخول والخروج.

❖ تحديد إشارات الشراء أو البيع عند تقاطع خط MACD مع خط الإشارة EMA لـ 9 فترات لخط MACD نفسه.

3.2 المتوسطات المتحركة (EMA20 . EMA50):

يفيد الشبكة:

❖ تحديد الاتجاه قصير ومتوسط الأجل

❖ كشف "تقاطع الذهب" و"تقاطع الموت" تلقائياً

❖ تحسين قدرة النموذج على فهم الدورات السعرية

4.2 مؤشر التذبذب ATR:

ATR = Average (True Range)

True Range = max (High-Low, |High-Close_prev|, |Low-Close_prev|)

يفيد الشبكة:

- يعلم الشبكة مقدار التقلب
- مهم في الأزمات وارتفاع التقلبات
- يساعد في توقع الحركات الحادة

معنى عمل المؤشر:

• High – Low

الفرق بين أعلى سعر وأقل سعر في نفس الشمعة، هذا هو المدى داخل نفس اليوم

• |High – Close_prev|

الفارق بين أعلى سعر اليوم وسعر إغلاق اليوم السابق، ونحتاجه ما إذا كان هناك (Gap) فجوة صعودية (السوق فتح أعلى بكثير من أمس).

• |Low – Close_prev|

الفارق بين أقل سعر اليوم وإغلاق اليوم السابق، يفيد فيما إذا كان هناك (Gap) هبوطي، فإن أقل سعر اليوم بالنسبة لإغلاق أمس يعكس الحركة الحقيقية.

بعدها نأخذ أكبر قيمة من هذه الثلاث قيم لأن مؤشر **True Range** يريد قياس أكبر حركة ممكنة أثرت على السوق بين أمس واليوم، سواء داخل الشمعة أو بسبب فجوات.

هناك 3 أنواع من الحركة:

❖ إذا كانت (High – Low) أعلى فالحركة داخلية (داخل الشمعة).

❖ إذا كانت (|High – Close_prev|) أعلى فهناك فجوة صعودية.

❖ إذا كانت (|Low – Close_prev|) أعلى فهناك فجوة هبوطية.

مثال:

نفترض:

$$\text{High} = 105$$

$$\text{Low} = 100$$

$$\text{Close_prev} = 98$$

نحسب القيم الثلاثة:

$$\text{High} - \text{Low} = 105 - 100 = 5$$

$$|\text{High} - \text{Close_prev}| = |105 - 98| = 7$$

$$|\text{Low} - \text{Close_prev}| = |100 - 98| = 2$$

$$\text{TR} = \max(5, 7, 2) = 7$$

السوق عمل فجوة صعودية من 98 إلى 105، وهي تمثل مصدر التذبذب الحاصل في السوق.

5.2 مؤشر الزخم (Momentum): يقيس سرعة أو معدل تغير سعر الأصل المالي وتحدد قوة وضعف الاتجاه السائد.

$$\text{Momentum} = \text{Close}(t) - \text{Close}(t-n)$$

يفيد الشبكة:

- يقيس سرعة الحركة وحركته في المدى القصير
- يعكس معنويات السوق ومدى استمرارية الاتجاه، لكن يجب استخدامه بحذر مع أدوات أخرى لتأكيد الإشارات.

3. البيانات المشتقة (Derived Features): هذه مميزات أكثر ذكاءً وتقدماً في التحليل الفني.

1.3 معدل التغير (Rate of Change – ROC): هو مؤشر فني يقيس سرعة تغير سعر الأصل خلال فترة زمنية محددة، ويعمل كمؤشر داعم لمؤشر الزخم ويتم رسمه كخط حول الصفر، حيث يشير فوق الصفر لزخم صاعد وتحت الصفر لزخم هابط.

$$\text{ROC} = (\text{Close}(t) / \text{Close}(t-n) - 1) \times 100$$

يفيد الشبكة:

- يُظهر متى يتباطأ أو يتسارع الاتجاه الصاعد أو الهابط.

- يساعد في تحديد إشارات ذروة الشراء (Overbought) وذروة البيع (Oversold) والانعكاسات المحتملة للاتجاه.

- يعطي إشارة لسرعة التغير

- يساعد النموذج على التمييز بين "اتجاه قوي" و"حركة جانبية"

2.2 التذبذب (Volatility): هو مقياس إحصائي لمدى تشتت أسعار الأصول المالية حول متوسطها، ويُعبّر عن حجم وسرعة تحركات الأسعار (صعوداً وهبوطاً).

يفيد الشبكة:

- يُعتبر مؤشراً على المخاطر وعدم اليقين، فارتفاعه (أكبر من 30) يعني تقلبات كبيرة ومخاطر أعلى، بينما يشير انخفاضه (أقل من 20) إلى استقرار السوق.

- تدريب النموذج على فترات الأزمة

أشهر طريقة: الانحراف المعياري لسعر الإغلاق لعشرة أيام سابقة.

$$Vol = \sigma = \sqrt{\frac{\sum (x_i - \mu)^2}{N}}$$

إذا كان **VOL=3** هذا يعني أنّ أسعار الإغلاق خلال آخر 10 أيام تتذبذب بي بحوالي 3 نقاط حول المتوسط.

3.3 ميل الاتجاه (Trend Slope): وهو مقياس أساسي لقوة وسرعة حركة السعر في اتجاه معين حيث يشير إلى زاوية أو انحدار خط الاتجاه.

$$Slope = (Close(t) - Close(t-n)) / n$$

أو باستخدام الانحدار الخطي على فترة زمنية.

$$Y_t = \beta_0 + \beta_1 X_t + \epsilon_t$$

يفيد الشبكة:

❖ يمثل الاتجاه رقمياً

❖ قياس قوة الاتجاه فكلما كان ميل الخط أكثر انحداراً (أكبر زاوية) كان الاتجاه أقوى وأسرع.

❖ الاتجاهات شديدة الانحدار قد تكون عرضة للتصحیح أو الانعكاس بشكل أسرع من الاتجاهات ذات الميل الأقل انحداراً.

❖ يساعد الشبكة على التعرف على الانعكاسات.

مثال: نفترض:

Close(t) 120

Close(t-10) = 100 (قبل 10 أيام)

n = 10

$$\text{Slope} = (\text{Close}(t) - \text{Close}(t-n)) / n = \frac{120-100}{10} = 2$$

يعني السعر كان يزيد في المتوسط بـ 2 نقطة كل يوم خلال آخر 10 أيام، وهذا اتجاه صاعد وبوتيرة منتظمة نسبياً.

4. البيانات الخارجية (External Features):

هي ما يميز النماذج الحديثة عن التقليدية لأنها تربط السوق بالعالم الحقيقي.

1.4 تحليل المشاعر أو الأخبار المعنوية (Sentiment Analysis):

يتم حسابها عبر تحليل النصوص (NLP) الذي ينبني على استخلاص رؤى قيمة من كميات هائلة من البيانات النصية غير المنظمة- مثل الأخبار، وتقارير الشركات، ووسائل التواصل الاجتماعي- وتحويلها إلى بيانات منظمة وقابلة للتحليل لدعم اتخاذ قرارات استثمارية. بالإضافة إلى نماذج أخرى تم تطويرها تعطي نتائج أحسن للتنبؤ الدقيق.

Sentiment Score من (سلبي) -1 إلى (إيجابي) +1

2.4 أسعار الفائدة (Interest Rates):

أسعار الفائدة المتغيرة مهمة لأنها:

- تتحكم في اتجاهات الذهب
- تؤثر على الأسهم (خصوصاً شركات النمو)
- تحدد قوة الدولار مقابل العملات

الشبكات تستخدمها لفهم "خلفية الاقتصاد الكلي".

3.4 البيانات الاقتصادية (Economic Events):

مثل مؤشر الوظائف الأمريكية، التضخم، محاضر اجتماع بنك الاحتياطي الفيدرالي، مؤشر ثقة المستهلك، الناتج المحلي

هذه البيانات يتم إدخالها ك:

- قيم رقمية
 - متغيرات ثنائية (0 = لم يحدث، 1 = حدث)
 - تأثير متوقع (إيجابي/سلبي)
- ميزة الشبكات العصبية أنها تستفيد من كل نوع بيانات بطريقة مختلفة:

OHLCV: الهيكل الأساسي للسعر.

المؤشرات الفنية: تنعيم وتفسير الاتجاه والزخم

البيانات المشتقة: رؤية رياضية للتغير السعري

البيانات الخارجية: حالة الاقتصاد الحقيقي

كلما زادت الميزات المختارة بعناية، أصبحت تنبؤات النموذج أدق وأكثر استقراراً.

ثالثاً: النماذج العصبية المستخدمة في التحليل المالي

- الشبكة الأمامية (FNN).
- الشبكات المتكررة (RNN).
- LSTM و GRU.
- الشبكات العصبية التلافيفية للتحليل البصري (CNN).

1) الشبكة الأمامية (Feedforward Neural Network - FNN):

تعتبر الشبكة الأمامية (FNN) من أبسط وأكثر أنواع الشبكات العصبية الاصطناعية شيوعاً. في هذه الشبكة، تتدفق المعلومات في اتجاه واحد فقط، من طبقة الإدخال عبر طبقات مخفية إلى طبقة الإخراج، دون وجود أي حلقات أو تغذية راجعة.

1.1 البنية والمبدأ: تتكون FNN من ثلاثة أنواع من الطبقات:

- **طبقة الإدخال:** تستقبل البيانات الأولية (الميزات).
- **الطبقات المخفية:** تقوم بمعالجة البيانات من خلال تطبيق وظائف تنشيط غير خطية.
- **طبقة الإخراج:** تنتج النتيجة النهائية (التنبؤ).

كل عقدة في طبقة ما متصلة بجميع عقد الطبقات السابقة وتساهم في حساب مخرجاتها بناءً على مدخلاتها ومصفوفة الأوزان المرتبطة بها. يتم تدريب الشبكة باستخدام خوارزمية التدرج المتناقص (Backpropagation) لتعديل هذه الأوزان وتقليل خطأ التنبؤ.

2.1 التطبيقات في تحليل الأسواق المالية: تُستخدم FNN بشكل واسع في المهام المالية التي لا تعتمد

بشكل كبير على الترتيب الزمني للبيانات، مثل:

- التنبؤ بأسعار الأسهم: بناءً على مجموعة من المؤشرات المالية والاقتصادية.
- تصنيف الحالة المالية: تحديد ما إذا كانت شركة معينة معرضة لخطر الإفلاس أم لا.
- تقييم المخاطر الائتمانية: التنبؤ بقدرة المقترض على سداد القرض.

3.1 المزايا:

- البساطة: البنية بسيطة وسهلة الفهم والتنفيذ.
- القدرة على التقاط العلاقات غير الخطية: قادرة على نمذجة العلاقات المعقدة بين المدخلات والمخرجات.
- فعالية في المهام غير المتسلسلة: مناسبة للمشكلات التي لا تتطلب فهمًا للسياق الزمني.

4.1 العيوب:

- عدم القدرة على التعامل مع السلاسل الزمنية: لا تحتفظ بأي معلومات عن البيانات السابقة، مما يجعلها غير مناسبة للتنبؤ بالأسعار المستقبلية بناءً على حركة الأسعار السابقة.
- الإفراط في التدريب: عرضة للإفراط في التدريب، خاصة في البيانات المالية التي تحتوي على ضوضاء عالية.

2. الشبكات المتكررة (Recurrent Neural Network - RNN):

تم تصميم الشبكات المتكررة (RNN) خصيصًا للتعامل مع البيانات المتسلسلة، مثل السلاسل الزمنية. على عكس FNN، تحتوي RNN على حلقات تغذية راجعة تسمح لها بتخزين "ذاكرة" للحالات السابقة، مما يمكنها من التقاط التبعية الزمنية في البيانات

1.2 البنية والمبدأ: في RNN يتم تمرير مخرجات العقد في وقت معين كمدخلات إلى العقد في الخطوة

الزمنية التالية. هذا يخلق حلقة تسمح للشبكة بمرور المعلومات عبر التسلسل، مما يعطيها القدرة على فهم السياق والنمط الزمني.

2.2 التطبيقات في تحليل الأسواق المالية: نظرًا لقدرتها على معالجة البيانات المتسلسلة، تُستخدم RNN

في مجموعة متنوعة من التطبيقات المالية، بما في ذلك:

التنبؤ بأسعار الأسهم: نمذجة حركة أسعار الأسهم كسلسلة زمنية.

تحليل المشاعر في الأخبار المالية: فهم المشاعر الإيجابية أو السلبية في النصوص المالية.

توقع أسعار الصرف: التنبؤ بحركة أسعار الصرف بناءً على البيانات التاريخية.

3.2 المزايا:

- القدرة على معالجة البيانات المتسلسلة: مصممة خصيصًا للتعامل مع البيانات التي لها ترتيب زمني.

- الذاكرة الزمنية: تحتفظ بمعلومات عن الحالات السابقة، مما يمكنها من فهم السياق.

4.2 العيوب:

- مشكلة الاندثار والتضخم في التدرجات: عند تدريب RNN على سلاسل زمنية طويلة، يمكن أن تصبح التدرجات إما صغيرة جدًا (اندثار) أو كبيرة جدًا (تضخم)، مما يصعب عملية التعلم.
- التعقيد الحسابي: عملية التدريب تستغرق وقتًا أطول من FNN بسبب الطبيعة التكرارية.

3. نماذج الذاكرة طويلة الأمد (LSTM) ووحدات التكرار المعتمدة (GRU):

LSTM (Long Short-Term Memory):

الذاكرة الطويلة والقصيرة المدى : المغلقة GRU (Gated Recurrent Unit):

تم تطوير نماذج LSTM و GRU كتحسينات على RNN التقليدية لمعالجة مشكلة الاندثار والتضخم في التدرجات. هذه النماذج مصممة للحفاظ على المعلومات الهامة على مدى فترات زمنية طويلة، مما يجعلها مثالية للتنبؤ بالسلاسل الزمنية المالية.

1.3 البنية والمبدأ: تحتوي (LSTM) على وحدات معقدة تسمى "خلايا الذاكرة" مزودة ببوابات (Gates)

تتحكم في تدفق المعلومات. هذه البوابات تسمح للشبكة بالاحتفاظ بالمعلومات المهمة والتخلي عن المعلومات غير الضرورية.

أما (GRU) نسخة مبسطة من LSTM تحتوي على بوابتين فقط بدلاً من ثلاث، هذا يجعلها أسرع في التدريب وأقل تعقيدًا من LSTM، مع الحفاظ على أداء مشابه في العديد من المهام.

2.3 التطبيقات في تحليل الأسواق المالية: تُعتبر LSTM و GRU من أكثر النماذج فعالية في التحليل المالي، وتُستخدم في:

- التنبؤ بأسعار الأسهم على المدى الطويل.
- تحليل المشاعر في النصوص المالية الطويلة.
- التنبؤ بحركة أسعار الصرف.

3.3 المزايا:

- القدرة على التقاط التبعيات طويلة الأمد: مصممة خصيصًا للتعامل مع السلاسل الزمنية الطويلة.
- التركيز على الأنماط الزمنية: قادرة على تحديد الأنماط المهمة في البيانات المالية.
- أداء عالي: أظهرت دراسات عديدة أنها توفر نتائج أفضل من RNN التقليدية.

4.3 العيوب:

التعقيد الحسابي: أكثر تعقيدًا ويتطلب وقتًا أطول للتدريب من FNN
احتياج البيانات: تحتاج إلى كميات كبيرة من البيانات للتدريب الفعال.

4. الشبكات العصبية التلافيفية (Convolutional Neural Network - CNN):

على الرغم من أن الشبكات العصبية التلافيفية (CNN) معروفة بشكل أساسي بقدرتها على معالجة الصور، إلا أن تطبيقاتها في التحليل المالي تزداد بشكل كبير فهي تُستخدم لتحويل الرسوم البيانية المالية إلى صور وتحليلها تلقائيًا للكشف عن الأنماط البصرية.

1.4 البنية والمبدأ: تتكون من طبقات تلافيفية (Convolutional Layers) تقوم بتطبيق مرشحات (Filters) على الصورة لاكتشاف الأنماط المحلية، مثل الحواف والزوايا. يتم تمرير هذه الأنماط إلى طبقات تجميع (Pooling Layers) لتقليل حجم البيانات والحفاظ على الميزات المهمة وأخيرًا يتم تمرير الميزات المستخرجة إلى طبقات FNN للتصنيف أو التنبؤ.

2.4 التطبيقات في تحليل السوق المالي: تفيد في:

- التحليل الفني الآلي: تحليل الرسوم البيانية للأسهم لاكتشاف أنماط مثل "رأس وكتفين"
- التنبؤ بأسعار الأسهم: بناءً على الصور المولدة من البيانات التاريخية.
- تحليل الشموع اليابانية (Candlestick Charts): التعرف على أنماط الشموع التي تشير إلى اتجاهات السوق.

3.4 المزايا:

- الكفاءة العالية في التعرف على الأنماط البصرية: قدرة على اكتشاف الأنماط المعقدة في الرسوم البيانية.
- القدرة على معالجة البيانات متعددة الأبعاد: مناسبة لتحليل الصور والرسوم البيانية.

4.4 العيوب:

- الحاجة إلى تحويل البيانات: تتطلب تحويل البيانات الزمنية إلى صور، مما قد يفقد بعض المعلومات.
- قلة القدرة على التقاط التبعيات الزمنية الطويلة: أقل فعالية من LSTM و GRU في معالجة السلاسل الزمنية الطويلة.

رابعاً: خطوات بناء نموذج شبكات عصبية للتنبؤ المالي

الخطوة 1: جمع البيانات

مثال: 200 يوم من أسعار سهم Apple

الخطوة 2: التجهيز (Preprocessing)

- التطبيع normalization
- تقسيم البيانات (Train/Test)
- تحويل السلسلة إلى نوافذ زمنية Sliding Windows

الخطوة 3: اختيار النموذج

أفضل نموذج للتنبؤ السعري LSTM

الخطوة 4: التدريب Training

تحديث الأوزان عبر خوارزمية Backpropagation Through Time (BPTT)

الخطوة 5: التقييم Evaluation

- RMSE
- MAPE
- دقة الإشارة (دقة الصعود/الهبوط) Up/Down accuracy

مثال: توقع سعر الغد باستخدام شبكة LSTM

نفترض أن لدينا سلسلة أسعار إغلاق لخمسـة أيام:

نقوم بإنشاء نافذة زمنية:

اليوم	السعر (Close)
1	100
2	102
3	104
4	101
5	103

Input = [100, 102, 104, 101]

Output = [103]

بعد تدريب النموذج على 1000 نافذة ماثلة، نتوقع:

كان السعر المتوقع لليوم 6 = 104.20

والسعر الحقيقي = 103.80

دقة التنبؤ:

الخطأ = $|103.80 - 104.20| = 0.40$ (دقة عالية جداً)

خامساً: الأخطاء استخدام الشبكات العصبية في تحليل بيانات السوق المالي

- استخدام شبكة كبيرة دون بيانات كافية
- تدريب أكثر من اللازم **Overfitting**
- عدم اختبار النموذج على فترة أزمت (2008 – كورونا)
- تجاهل المتغيرات الاقتصادية الكلية.