

8/ تصور الأنماط في البيانات المحاسبية باستخدام خرائط التنظيم الذاتي توركو لعلوم الكمبيوتر ، كلية توركو للاقتصاد وإدارة الأعمال ، الشبكات العصبية هي طرق تعتمد على البيانات. أنها توفر معلومات إضافية لعملية اتخاذ القرار كما قد تترك مخفية من ناحية أخرى. تم بالفعل تطبيق الشبكات العصبية في العديد من مجالات الأعمال المختلفة. ويمكن استخدامها للتنبؤ والتصنيف والتجميع. يمكنهم أن يتذكروا ويقارنوا الأنماط المعقدة. يوضح هذا الفصل كيف يمكن استخدام الشبكة العصبية، وخاصة خريطة Kohonen ذاتية التنظيم (SOM) ، في تصور البيانات المحاسبية المعقدة. يستخدم SOM لتجميع عشر سنوات من بيانات الدخل الشهري لشركة تصنيع. والغرض من ذلك هو إظهار كيف تشكل مجموعات البيانات لمختلف الحسابات والسنوات مجموعات الخاصة. وجدنا أن SOM يمكن أن يكون أداة مساعدة بصرية لتصنيف مجموعات البيانات وتجميعها، وأنه يكشف ما إذا كانت بعض المجموعات تحتوي على بيانات لا ينبغي أن تكون موجودة فيها. وبالتالي، يمكن استخدامه للإشارة إلى تقلبات غير متوقعة في البيانات. علاوة على ذلك، فإن SOM هي تقنية ممكنة مضمنة في أداة المراقبة المستمرة والتصديد. يهتم العديد من الأطراف، مثل المستثمرين والدائنين والمديرين، بدقة قيم الحسابات المالية للمؤسسة. يرغب المديرون في تقدير الإيرادات والنفقات المستقبلية من أجل تحسين العمليات خلال فترة معينة. يرغب المدققون في تقييم دقة البيانات المالية للمؤسسة. يريد الدائنون تحليل قدرة المنظمة على الدفع. قد تستفيد جميع هذه الأطراف من أداة تراقب وتصور البيانات المحاسبية المعقدة. يمكن أن تكون إحدى التقنيات الممكنة المضمنة في أداة المراقبة هي الشبكة العصبية الاصطناعية (ANN). الشبكات العصبية الاصطناعية ليست تقنيات رسمية إحصائية مسبقة ولكنها بدلا من ذلك تقنيات تعتمد على البيانات. وقد تم بالفعل تطبيق شبكات ANN في العديد من مجالات الأعمال المختلفة. (Vellido et al. 1999, Zhang et al. 1998), يمكنهم تعلم وتذكر ومقارنة الأنماط المعقدة. (Dutta 1993) إنهم قادرون على اكتشاف علاقات البيانات. على سبيل المثال ، على عكس التقنيات الإحصائية التقليدية ، فإن ANNs قادرة على تحديد ومحاكاة العلاقات غير الخطية في البيانات دون أي افتراضات مسبقة حول خصائص توزيع البيانات. على سبيل المثال ، على عكس التقنيات الإحصائية التقليدية ، فإن شبكات ANN قادرة على تحديد ومحاكاة العلاقات غير الخطية في البيانات دون أي افتراضات مسبقة حول خصائص توزيع البيانات. تتعلم الشبكات العصبية الاصطناعية من الأمثلة ثم تعمم على الملاحظات الجديدة. فهم يقدمون معلومات إضافية لعملية اتخاذ القرار حيث قد تترك مخفية بخلاف ذلك. هذه الميزات تجعل شبكات ANN مناسبة للعديد من المهام داخل المحاسبة. وقد مكنت قدرات تطوير تكنولوجيا المعلومات ومعالجتها لأجهزة الكمبيوتر من نمذجة نظم المعلومات القائمة على شبكة الإنترنت لرصد العمليات والتحكم فيها. طور الباحثون مجموعة متنوعة من نماذج ANN للمساعدة في المراقبة ومراقبة العمليات مثل اكتشاف الأخطاء المادية. في البيانات (كوكلي وبراون 1991 أ ، كوكلي وبراون 1991 ب ، كوك لي وبراون 1993 ، وو 1994 ، كوكلي 1995 ، بوستا وواينبرغ 1998 ، كوسكيفارا 2000)، كشف الاحتيال الإداري (جرين وتشوي 1997 ، فانينغ وكوجر 1998 ، فيروز وآخرون. 2000) ، ودعم الذهب يخدم سيرن القرار (هانسن وآخرون. 1992 ، لينارد وآخرون. 1995 ، كوه وتان 1999 ، أناندراجان وأناندراجان 1999 ، إثريديج وآخرون. 2000). كما تم تطبيق أنس لتقييم المخاطر الرقابة الداخلية (ديفيس وآخرون. 1997 ، رامامورتي وآخرون. 1999) ومشاكل الضائقة المالية (فانينغ وكوجر 1994). توجه تطبيقات الأخطاء المادية انتباه المستخدمين إلى قيم الحسابات المالية التي لا تتوافق فيها العلاقات الفعلية مع العلاقات المتوقعة. يجب على المستخدم أن يقرر ما إذا كان هناك نوع من التحقيق الإضافي المطلوب لشرح النتائج غير المتوقعة. نماذج ANN للاخطاء المادية إما تتنبأ بالقيم المستقبلية أو تصنف البيانات. تبدو نتائج نماذج الأخطاء المادية واعدة، على الأقل ككملة لإجراءات التدقيق التحليلي التقليدية، وتقدم أداء غير مثبت في التعرف على الأخطاء الجوهرية في الحسابات المالية. الشركات تستخدم أو استخدمت تطبيقات ANN لدعم أعمالهم. تستخدم شركات بطاقات الائتمان تقنية ANN للكشف عن العملاء المحتالين (مولكوين 1996 ، فراير 1996 ، فيشر 1999). وقد طورت KPMG Peat Marwick بالفعل ANN للتنبؤ بالإفلاس (إثريديج وآخرون. 1994). طبقت شركة بوهيولا "Pohjola" للتأمين حل ANN لتسويقها المباشر (سينكونن ولاهتينن 1998). في هذا الفصل ، نعرض جدوى شبكة ANN ، وخاصة خريطة Kohonen ذاتية التنظيم (SOM) ، في مراقبة قيم الحساب في البيانات الشهرية القادمة من شركة التصنيع. ندرس ما إذا كان SOM قادرا على الكشف عن الاختلافات والمجموعات الشهرية في مجموعات البيانات في المسألة ذات المغزى. باقي من الفصل مُنظم كما يلي: القسم 2.8 يصف منهجية البحث. يتضمن هذا القسم وصفاً موجزاً لخرائط SOM، واختيار قيم الحسابات المالية المستخدمة في هذه التجربة. يقدم القسم 3.8 بناء الخرائط الذاتية التنظيمية، ويقدم القسم 4.8 تحليلاً مفصلاً للخرائط ويقدم إرشادات لتنفيذ هذا

النوع من النموذج. تُعرض استنتاجات هذه الورقة في القسم 5. SOM هو طريقة التجميع والتصور، والغرض من ذلك هو إظهار مجموعة البيانات في شكل تمثيل آخر (كوهونين 1997). يقوم بإنشاء خريطة ثنائية الأبعاد من n -بيانات ادخال الأبعاد. تشبه هذه الخريطة منظرا طبيعيا يمكن من خلاله تحديد الحدود التي تحدد المجموعات المختلفة. تتكون هذه المجموعات من متغيرات الإدخال ذات الخصائص المتشابهة، أي في هذا التقرير، التباين الشهري لقيم الحساب. تستمر تجارب التدريب ذاتية التنظيم حتى يتم تعيين عنصرين إدخال قريبين في مساحة الإدخال في نفس الخلايا العصبية أو الخلايا العصبية المجاورة على الخريطة. الخلايا العصبية الناتجة تخلق مجموعات ؛ والتي تشكل معا خريطة للخلايا العصبية المدخلة. يحتوي SOM على ستة معلمات تعليمية، الهيكل، نوع الحي، الأبعاد X و Y ، معدل التدريب، طول التدريب، ونصف قطر الشبكة. تشير طوبولوجيا الشبكة إلى شكل الشبكة. هناك نوعان من الشبكات شائعة الاستخدام، مستطيلة وسداسية (الشكل 8.1). في شبكة مستطيلة، ترتبط كل خلية عصبية بأربعة جيران، باستثناء تلك الموجودة على حافة الشبكة الصغيرة. في الشبكة التي استخدمناها بالكامل، تم ترتيب الخلايا العصبية الناتجة في بنية شبكية سداسية. هذا الترتيب يربط كل خلية عصبية بستة جيران تماماً، باستثناء تلك الموجودة على حافة القليل. تم اتخاذ هذا الاختيار وفقاً لإرشادات كوهونين (1997)، حيث توقعنا أن يوفر SOM بعض الفوائد للرصد بسبب قدرته على التصور. يشير نوع الحي إلى وظيفة الحي المستخدمة، وتكون الخيارات غاوسية وفقاعية. تشير الأبعاد X و Y إلى حجم الخريطة. في الخرائط الصغيرة جداً، يصعب تحديد الاختلافات بين المجموعات؛ وفي الخرائط الكبيرة جداً، ستظهر المجموعات مسطحة. يشير عامل معدل التدريب إلى مقدار ما تتعلمه الخلية العصبية الموجودة في جوار الخلية العصبية الفائزة من ناقل البيانات المدخلة. يقيس طول التدريب وقت المعالجة، أي عدد التكرارات من خلال بيانات التدريب. يشير نصف قطر الشبكة إلى عدد العقد حول الخلية العصبية "الفائزة" التي تتأثر أثناء عملية التعلم. تنقسم عملية تدريب الشبكة إلى قسمين. في الجزء الأول، تم تدريب الخريطة "تقريباً". في الجزء الثاني، تم ضبط الشبكة بشكل دقيق. استخدمنا بيانات فعلية تتألف من عشر سنوات من بيانات الدخل الشهري لشركة تصنيع. كانت الشركة شركة متوسطة الحجم في فنلندا، وبلغ صافي مبيعاتها حوالي 11 مليون يورو لكل سنة. بمساعدة مدقق حسابات محاسب قانوني معتمد (CPA)، مثلت الحسابات المختارة فئات البيانات الشهرية الرئيسية والأكثر إثارة للاهتمام. يتم عرض الحسابات ومتوسطاتها الشهرية بألف يورو في الجدول 1. أسباب اختيار الحسابات المذكورة أعلاه لنماذجنا هي كما يلي. • صافي المبيعات (NS) هي قيمة كبيرة يجب مراقبتها. في هذه الحالة بالذات، يكون الاختلاف بين جويلية والأشهر الأخرى كبيراً لأن الشركة مغلقة في جويلية. من وجهة نظر الإدارة، من الأفضل أن تكون القيمة الفعلية أكبر من القيمة المدرجة في الميزانية لأنه بعد ذلك يكون هناك عدد أقل من خيبات الأمل. من وجهة نظر المدقق، قد يثير هذا السيناريو شكوكاً حول ما إذا كانت جميع المبيعات مسجلة إذا كانت القيمة الفعلية أقل بكثير من قيمة التنبؤ. من ناحية أخرى، إذا كانت القيمة الحسابية أعلى بكثير من قيم التنبؤ، فربما تكون الشركة قد سجلت بعض المبيعات الوهمية. • يجب أن تخبر المواد (Mat) + التغيير في المخزون (CinIn) مع إجمالي استخدام المواد خلال فترة معينة. يجب أن تكون القيمة متوافقة مع صافي المبيعات لأن هذه شركة تصنيع. • يجب أن تكون تكاليف الموظفين (PC) متوافقة مع الإنتاج والاستخدام الكامل للمواد. • الهامش الإجمالي (GM) هو قيمة مهمة على الأقل من وجهة نظر التنبؤ كما هو الحال في رؤية مقدار الأموال المتبقية لتغطية التكاليف والأرباح غير المباشرة. • الإدارة (ADM) يظهر الاتجاه العام للتكاليف في الشركة وفي مجال الأعمال. • يشير إجمالي غير مباشر (TotInd) إلى جميع التكاليف الثابتة. يجب التنبؤ بهذه القيمة في جميع الحالات لأن هذه التكاليف لا تعتمد على المبيعات. • الربح التشغيلي (OP) هو قيمة مثيرة للاهتمام على الأقل من وجهة نظر التنبؤ. علاوة على ذلك، من المهم أن نرى أن العملية مربحة على المدى الطويل. • الذمم المدينة (Rec) هي قيمة مثيرة للاهتمام ومهمة يجب اتباعها من أجل معرفة مقدار أموال الشركة "الخارجية". • الدين التجاري (TD) يوضح المبلغ الذي يتعين على الشركة دفعه "في الخارج". يجب أن تكون الذمم المدينة والديون التجارية متوافقة مع صافي المبيعات. 4.8 التجميع باستخدام SOMs لغرض التجميع، استخدمنا الإصدار 3.1 من حزمة برنامج خريطة التنظيم الذاتي، التي أنشأها فريق برمجة SOM بجامعة هيل سينكي للتكنولوجيا في بناء الشبكة (كوهونين وآخرون. 1995). لتصور نتائج SOM، استخدمنا Nenet - الإصدار التجريبي 1a الذي أنشأه فريق Nenet (إلوما وآخرون. 1999). Nenet هو برنامج سهل الاستخدام مصمم لتوضيح استخدام SOMs، كما أنه يوفر خرائط مستوى المعلومات الفردية ومستويات الميزات. يناسب مكان الإقامة هذا أغراضنا تماماً، لأننا نريد مقارنة الحسابات والأشهر المختلفة مع بعضها البعض. قمنا ببناء نوعين مختلفين من الخرائط بمتجهات إدخال مختلفة. أولاً، قمنا ببناء خريطة بحيث توجد في المتجه البيانات الشهرية

للحساب سنويا كعناصر متجهة. باستخدام هذه الخريطة A ، أردنا أن نرى كيف تقع الحسابات المختلفة مقارنة ببعضها البعض وبقيم السنوات السابقة. ثانياً، قمنا ببناء خريطة بقيم بيانات شهر معين كقيم متجهة وقدمناها في ترتيب زمني للشبكة العصبية. باستخدام هذه الخريطة B ، أردنا معرفة ما إذا كانت هناك أي اتجاهات سنوية في مجموعات البيانات. تشبه هذه الخرائط إجراءات التدقيق التحليلي مثل مقارنة المعلومات الحالية بمعلومات مماثلة لفترات سابقة ودراسة العلاقات بين عناصر المعلومات (غونت وآخرون. 1997). هناك بعض الإرشادات التي يجب اتباعها عند إنشاء الخرائط. يجب أن تكون الخريطة مستطيلة ، وليست مربعة ، من أجل تحقيق استقرار في مساحة البيانات. عادة ، يجب أن يكون المحور x أكبر بحوالي 30 بالمائة من المحور y ، وبالتالي تشكيل خريطة إخراج مستطيلة. توصية أخرى هي أن مدة التدريب للجزء الثاني يجب أن تكون على الأقل 500 ضعف عدد وحدات الشبكة من أجل الوصول إلى الدقة الإحصائية (Kohonen 1997). اخترنا واحدة حيث تتكون الطبقة من 35 خلية عصبية مرتبة في شبكة سداسية $5 * 7$. كما ذكرنا سابقاً ، تعتبر المشابك السداسية جيدة لأغراض التصور. كانت وظيفة الحي هي الفقاعة. وكانت مدة التدريب ومعدل التدريب في المرحلة الأولى 1750 و 5.0 وفي المرحلة الثانية ، 17500 و 0.05. كان نصف قطر الحي في المرحلة الأولى 9 وفي المرحلة الثانية 1. لتصور الخريطة النهائية ذاتية التنظيم ، استخدمنا مصفوفة المسافة الموحدة (Umatrix). يمكن استخدام طريقة V-matrix هذه لاكتشاف العلاقات غير المرئية الحكيمة الأخرى في مساحة بيانات عالية الأبعاد. كما أنه يجعل من الممكن تصنيف مجموعات البيانات إلى مجموعات من القيم المتشابهة. أبسط طريقة V-matrix هي حساب المسافات بين الخلايا العصبية المجاورة وتخزينها في المصفوفة ، أي خريطة الإخراج ، والتي يمكن تفسيرها بعد ذلك. إذا هناك "جدران" بين الخلايا العصبية ، فإن الخلايا المجاورة بعيدة ، أي أن القيم تختلف اختلافاً كبيراً. يتم عرض قيم المسافة أيضاً بالألوان عند تصور مصفوفة V. على الخرائط ، نحدد المجموعات من خلال النظر إلى ظلال الألوان للحدود بين الأشكال السداسية. تمثل الألوان الداكنة في الجدران مسافات كبيرة بينما تشير الألوان الأكثر إشراقاً إلى أوجه التشابه بين الخلايا العصبية. الحدود الملونة بين الأشكال السداسية ذات قيمة كبيرة عند محاولة تحديد وتفسير المجموعات. من خلال عرض مستويات المعالم الفردية ، من الممكن تصور قيم عمود متجه واحد ، أي في هذه الدراسة ، الخرائط لمدة شهر واحد (خرائط A) أو لحساب واحد (خرائط B). يمكن تصور هذه الطائرات المميزة من أجل اكتشاف كيفية أداء الشركة وفقاً لأشهر مختلفة أو حسابات مختلفة. نظراً لأننا اخترنا الحسابات التي تعتمد على بعضها البعض ، يجب أن تكون مستويات الميزات للأشهر متشابهة إلى حد ما. بعد ذلك نوضح كيف يمكن استخدام مخرجات SOM كوسيلة مساعدة بصرية لتصنيف وتجميع قيم بيانات الدخل الشهري على مدى عشر سنوات. يقوم المستخدم بتحليل مجموعات الحسابات والاختلافات في مستويات المعالم الشهرية من أجل معرفة ما إذا كانت المجموعات قريبة بما يكفي من بعضها البعض أو ما إذا كانت هناك أي اختلافات كبيرة بين مستويات المعالم الشهرية (A-map). قد يقوم المستخدم بتحليل ما إذا كانت قيم الحساب قريبة بما يكفي من قيم العام السابق (B-map). إذا كان الفرق كبيراً ، فيجب على المستخدم أن يقرر مقدار ونوع التحقيق الإضافي المطلوب. عند دراسة مستويات المعالم الشهرية الأساسية للخريطة A (الشكل 2.8) والخريطة A النهائية (الشكل 3.8) ، تم تحديد عدد من مجموعات الحسابات وخصائص هذه المجموعات (الشكل 4.8). تظهر مستويات المعالم في الشكل 2.8 خريطة لكل شهر في هذه الدراسة حيث يمثل اللون الأحمر في الزوايا اليسرى السفلية قيماً عالية ، والتي تعني في حالتنا حسابات الإيرادات. تظهر الألوان الداكنة في الزوايا اليمنى السفلية قيماً سالبة ، والتي تعني في حالتنا حساب دين تجاري. من هذه الطائرات المميزة ، نرى أنه لا يوجد سوى اختلاف بسيط بين الأشهر. على سبيل المثال ، في الطائرات المميزة لشهري يونيو ويوليو ، توجد خلايا عصبية أخف قليلاً في المنتصف مقارنة بمعالم الأشهر الأخرى. ومع ذلك ، فإن مستويات الميزات في الأشهر متشابهة جداً بحيث لا يعطي أي سبب لمراجعة الآثار. هذه النتيجة تعني أن العلاقات بين الحسابات المدرجة في هذه الدراسة مستقرة تماماً خلال العام. إذا كان مستوى الميزة لهذا الشهر يختلف كثيراً عن مستويات الميزات الأخرى ، فهذا تلميح للمستخدم للتحقيق أكثر. في الشكل 4.8 ، قمنا بتسمية مجموعات محددة وفقاً للحسابات التي تحتوي عليها هذه المجموعات. قمنا بتسمية حسابات العامين الماضيين لمعرفة ما إذا كانت الحسابات قريبة لبعضها البعض ولتسمية المجموعات. حددنا أربع مجموعات رئيسية: الإيرادات ، والهوامش ، والقوالب ، والديون التجارية. كان من السهل تحديد مجموعات الإيرادات والديون التجارية بناءً على مستويات الميزات في الأشهر المختلفة. على الرغم من أن الديون التجارية في العامين الماضيين هي في نفس الخلية العصبية ، إلا أن المجموعة نفسها أكبر بكثير لأن قيم الديون التجارية للسنوات السابقة كانت أكثر انتشاراً على الخريطة. يمكن أن تكون مجموعة الإيرادات أكبر بناءً على الطائرات

المميزة في مارس ويونيو ويوليو وأغسطس. ومع ذلك ، فإن تصنيف الهامش الإجمالي والربح التشغيلي يكشف أن هذه الخلايا العصبية تنتمي إلى مجموعة الهوامش. تقع جميع حسابات التكلفة في دراستنا في الزاوية اليمنى العليا. لذلك؛ أطلقنا عليها اسم مجموعة التكلفة. الذمم المدينة (Rec) ، صافي المبيعات (NS) ، الربح التشغيلي (OP) ، تكاليف الموظفين (PC) ، التغيير في المخزون (CinIn) ، الإدارة (Adm) ، والمواد (Mat) من العامين الماضيين في نفس الخلايا العصبية. الهامش الإجمالي (GM) والإجمالي غير المباشر (TotInd) لعامي 1998 و 1999 في خلايا عصبية مختلفة. يشير هذا الموقع إلى أن التباين الشهري النسبي لقيمة الحساب من الهامش الإجمالي وإجمالي غير المباشر أكبر من قيمة الحسابات الأخرى في هذه السنوات. تسمح أيضا ل SOM بتجميع الحساب على أساس الشهر. باستخدام هذه الخريطة B، أردنا معرفة ما إذا كانت الأشهر قريبة من بعضها البعض وما إذا كانت السنوات المختلفة قريبة من بعضها البعض. قمنا بتحليل خريطة B باستخدام مستويات معالم الحساب (الشكل 8.5) ومن خلال تسمية جميع الأشهر على الخريطة. وجدت هذه الطريقة ست مجموعات في الخريطة. توجد المستويات المميزة لصافي المبيعات والهامش الإجمالي والربح التشغيلي والذمم المدينة في الجزء العلوي من الشكل 8.5. هذه الحسابات موجودة في عينتنا حسابات الدخل حيث يوضح اللون الأحمر القيم العالية ، والتي تقع على الجانب الأيسر من مستويات الميزة. تبدو التوقعات العامة لصافي المبيعات والهامش الإجمالي والربح التشغيلي متشابهة للغاية. المعالم المميزة للمواد، والتغيير في المخزونات ، وتكاليف الشخص ، والإدارة في المنتصف. تكاليف المواد والموظفين لها نفس النظرة العامة لصافي المبيعات على الرغم من أن الألوان معاكسة. يجب أن تكون هذه الحسابات في محاذاة. المستويات المميزة لإجمالي الديون غير المباشرة والتجارية هي على المحصلة النهائية. في هذه المعالم المميزة. كلما كان اللون أغمق، زادت التكلفة. في الشكل 8.6 ، قمنا بحساب عدد البيانات الشهرية للسنة التي تنتمي إلى مجموعة واحدة في الخريطة B. نرى أيضا ميلا يبدأ من الزاوية اليمنى السفلى، حيث توجد بيانات أوائل التسعينيات، صعودا نحو أعلى الخريطة ثم إلى الزاوية اليسرى السفلية ومرة أخرى صعودا نحو أعلى الخريطة. يبدو أن أفضل أداء هو في الزاوية اليسرى السفلية حيث توجد البيانات الشهرية من عام 1998. جميع بيانات يوليو هي في الخلايا العصبية المحصلة النهائية. توجد بيانات السنوات السبع الأولى من شهر يوليو في الزاوية اليمنى السفلية النهائية من الخريطة. يتم أيضا تجميع بيانات يوليو من 1997-1999 في الخلايا العصبية اليمنى السفلية لمجموعات هذه السنوات. نوضح أيضا أسود الحركة الشهرية في عام 1998 وبسهم أبيض الحركة الشهرية في عام 1999 (الشكل 8.7). من هذه الأسهم ، نرى أن حركة البيانات الشهرية لعام 1999 على الخريطة B أوسع بكثير. والسبب في الحركة الأكثر إحكاما لبيانات عام 1998 هو أن قيم الحسابات في تلك السنة هي الأكبر في مجموعة البيانات بأكملها؛ وبالتالي ، فقد تركزو في زاوية واحدة. وينطبق نفس السبب ولكن المعاكس على بيانات جويلية، لا سيما مع السنوات 1990-1996. قيم الحساب هذه هي الأصغر في مجموعة البيانات بأكملها ، وبالتالي ، فقد تركزت في الزاوية اليمنى السفلية. نلاحظ أيضا من الشكل 8.7 أن كلا السهمين يبدأ من الخلايا العصبية المجاورة وينتهي بها. لتسهيل عملية تعلم الشبكة العالمية للشبكات العصبية وتحسين جودة الخريطة، غالبا ما تتم معالجة البيانات مسبقا بطريقة ما. لم نستخدم أي طريقة معالجة مسبقة ، لأننا أردنا حساب متوسط قيم الحساب لعام 1999 بناء على قيم المتجهات في خرائط الإخراج. في الجدول 8.2 ، نقارن متوسط قيم الحساب الشهرية الفعلية بالقيم المحسوبة من قيم المتجهات لخريطة A وخريطة B. في المتوسط، يبدو أن ترتيب المتجهات الذي لدينا في خريطة B أفضل من ترتيب المتجهات في الخريطة A إذا قارنا قيم متجه الإخراج. لقد زرنا استخداما إضافيا للمواد في البيانات لمعرفة ما إذا كان SOM يتعرف على أي فرق. لقد تلاعبنا بالبيانات عن طريق مضاعفة استخدام المواد في ديسمبر 1999 لرؤية التأثيرات على الخرائط والطائرات المميزة. هذا التأثير صغير جدا بالنظر إلى أنه في خريطة واحدة لدينا جميع البيانات من السنوات العشر مرئية في نفس الوقت. في الشكل 8.8 ، نوضح كيف تتغير مستويات المعالم في الخرائط بسبب هذا التلاعب. على الجانب الأيسر من الشكل ، لدينا مستويات الميزات للبيانات الأصلية ؛ وعلى الجانب الأيمن ، لدينا مستويات الميزات للبيانات التي تم التلاعب بها. تستند مستويات المعالم في الجزء العلوي من الشكل إلى الأشهر (A-map) ، وتستند مستويات المعالم في أسفل الشكل إلى الحسابات (B-map). توضح الخلايا العصبية البيضاء الموجودة على اليسار المكان المناسب للمتجه. تظهر الخلايا العصبية البيضاء على اليمين مكان متجهات البيانات التي تم التلاعب بها. لقد قمنا أيضا بتدوير تأثيرات التلاعب على الخريطة بأكملها. يقع الاستخدام الشهري للمادة في نفس الخلية العصبية في كلتا الحالتين (انظر الشكل 8.8). مستويات الميزة العلوية). ومع ذلك، فقد تغير لون الخلايا العصبية المجاورة بشكل كبير. في حساب مستويات المعالم، يكون التغيير أكثر جذرية. تبدو مستويات

المعالم بأكملها مختلفة تماما. وقد أدى التلاعب إلى تعثر مستويات المعالم بأكملها من الداخل إلى الخارج. وقد غيرت الخلية العصبية مكانها، وتغيرت ألوان الخلايا العصبية المجاورة. يصور الشكل 9.8 إطار نموذج تحليل الأنماط القائم على SOM في البيانات المحاسبية. بشكل عام ، يجب أن توضح هذه البيانات المحاسبية عملية الأعمال. يستفيد SOM من البيانات الموجودة بالفعل في أنظمة المحاسبة. يستخدم SOM البيانات ويعطي تصورا مضغوطة وممتازا لها. علاوة على ذلك، فإنه يجمع البيانات بطريقة ذات معنى. يعطي SOM نوعا جديدا من المعلومات للمحللين البشريين ، وبالتالي يجعل التفاعل بين الفاعل البشري ونظام المعلومات ممكنا. بشكل عام ، قد يقوم الفاعل البشري بتحديث النموذج بثلاث طرق. أولا ، يمكنهم إجراء تغييرات في العمليات التجارية. على سبيل المثال ، تخصيص استخدام المواد في الوقت المناسب في النظام المحاسبي. ثانيا ، يمكنهم تصحيح البيانات الخاطئة. على سبيل المثال ، خذ جميع المبيعات الوهمية من سجلات مسك الدفاتر. ثالثا ، قد يقوم الفاعل البشري بتحديث النموذج إما عن طريق تغيير المعلومات في النموذج أو عن طريق تغيير متغيرات النموذج. في هذا الفصل، أوضحنا كيف يمكن استخدام SOM في تصور قيم بيان الدخل الشهري. تم استخدام SOM لتجميع مجموعات البيانات، وكان الغرض هو إظهار قيم الحساب في نموذج تمثيل آخر. لقد سمحنا ل SOM بتجميع بيانات الحساب الشهرية لشركة تصنيع من عشر سنوات. وجدنا أن SOM هي أداة لتصنيف مجموعات البيانات هذه والحسابات المماثلة تشكل مجموعاتها بالقرب من بعضها البعض. نحن نجادل بأن SOM يمكن أن يساعد المستخدمين من خلال تصور المخالفات في البيانات وتوجيه المستخدم إلى قلب المشكلة. يستخدم SOM البيانات بأكملها ويجد مجموعات متجانسة في البيانات. مع تضمين SOM في نظام المراقبة، من الممكن رسم صورة على الشاشة من مجموعات البيانات المعقدة ، على سبيل المثال مرة واحدة في الشهر ، وتقديم مساعدة بصرية لمحللي بيانات الأعمال. استخدمنا القيم الشهرية للحساب، ولكن يمكن أيضا استخدام SOM لتحليل جميع معاملات حسابات معينة. يعد تطوير وتقييم طرق التحليل المتقدمة مثل شبكات ANN في سياق محاسبي والمراقبة والتحكم المستمرين أمرا مهما من أجل تزويد المستخدمين بوسائل أكثر كفاءة وفعالية لمراقبة قيم الحسابات. هذه المراقبة هي إحدى الطرق لاستعادة ثقة الجمهور في نظام سوق رأس المال ومهنة المحاسبة ، والتي اهتزت بسبب انهيار إنرون وآرثر أندرسن وما إلى ذلك.